Albert-Ludwigs-Universität Freiburg
Fakultät für Angewandte Wissenschaften
Institut für Informatik

Visuelle Orientierung in Innenräumen mit einer Kamera

Diplomarbeit

Jörg-Dieter Stückler

Angefertigt in der
Nachwuchsgruppe Humanoide Roboter

Abgabedatum: 27. September 2007

Erstgutachter : Dr. Sven Behnke
Zweitgutachter : Prof. Dr. Wolfram Burgard

Erklärung

Hiermit versichere ich, dass ich diese Abschlussarbeit selbständig verfasst habe, keine anderen als die angegebenen Quellen/Hilfsmittel verwendet habe und alle Stellen, die wörtlich oder sinngemäß aus veröffentlichten Schriften entnommen wurden, als solche kenntlich gemacht habe. Darüber hinaus erkläre ich, dass diese Abschlussarbeit nicht, auch nicht auszugsweise, bereits für eine andere Prüfung angefertigt wurde.

Freiburg, 27. September 2007 _____

(Jörg-Dieter Stückler)

Danksagung

An dieser Stelle möchte ich all jenen danken, die mich während der Bearbeitung meiner Diplomarbeit unterstützt haben.

Mein besonderer Dank gilt Dr. Sven Behnke, der mich mit seiner fachlichen Beratung und präzisen Kritik durch diese Arbeit geleitet hat und dessen Tür jederzeit für Fragen offenstand.

Ich bedanke mich bei Prof. Dr. Wolfram Burgard, dass er diese Arbeit ermöglicht hat. Für die wertvollen Anregungen zur Gestaltung dieser Arbeit möchte ich mich bei Dr. Maren Bennewitz und Michael Schreiber bedanken, wie ich allen Beteiligten der Nachwuchsgruppe Humanoide Roboter für ihre Geduld und Aufmunterung während der vergangenen Monate danken möchte.

Schliesslich möchte ich mich bei meinen Eltern bedanken, die mich während meines Studiums immer unterstützt haben.

Kurzfassung

Menschen orientieren sich in Innenräumen visuell und gestalten diese Umgebungen oftmals nach Kriterien, die sie bei der Orientierung unterstützen. Neben der farblichen Hervorhebung von Objekten besitzen Innenräume häufig die Eigenschaft, dass Parallelität und Orthogonalität von Wänden eine klare Struktur bieten, welche die visuelle Orientierung erleichtert. In dieser Arbeit wird ein Verfahren zur simultanen Lokalisierung und Kartierung (SLAM) mit einer einzelnen Kamera untersucht, das typische Eigenschaften solcher Umgebungen ausnutzt. Das Verfahren schätzt die Trajektorie der Kamera in der horizontalen Ebene und lernt simultan eine zweidimensionale Umgebungsrepräsentation, welche die Wandstruktur der Umgebung modelliert.

Zunächst wird das Verfahren unter Verwendung von Odometrie und reinen Winkelmessungen in einer Simulationsumgebung entwickelt. In eindimensionalen Bildern werden Kanten- und Blobmerkmale skaleninvariant detektiert und beschrieben, die als Observationen von punktförmigen Landmarken im SLAM-Verfahren verwendet werden. Zwischen Kantenlandmarken werden visuell beobachtete Wände modelliert. Es werden schliesslich Techniken entwickelt, die das SLAM-Verfahren mit Hilfe des Wandmodells verbessern.

Der Ansatz wird anschliessend auf ein reales Innenraumszenario übertragen. Die Bewegung der Kamera wird mit einem Inertialsensor geschätzt und es wird eine zusätzliche visuelle Informationsquelle erschlossen. Tiefe wird am Übergang zwischen Fussboden und Wänden extrahiert, der in vielen Innenräumen klar erkennbar ist. Diese geschätzte Tiefe wird zur Erweiterung des SLAM-Verfahrens und zur Bewegungsschätzung verwendet.

Inhaltsverzeichnis

1 Einleitung **1**
1.1 Zielsetzung . . . 2
1.2 Aufbau dieser Arbeit . . . 2

2 Verwandte Arbeiten **5**

3 Grundlagen **9**
3.1 Systemgrößen . . . 9
3.2 Probabilistische Zustandsschätzung . . . 10
3.3 Rekursive Bayessche Filter . . . 11
3.3.1 Das erweiterte Kalmanfilter . . . 12
3.3.2 Das Partikelfilter . . . 13
3.3.3 Rekursives Filter für statische, binäre Zustände . . . 15
3.4 Lokalisation . . . 16
3.5 Kartieren von Landmarken . . . 17
3.6 Simultanes Lokalisieren und Kartieren . . . 19
3.6.1 Landmarkenbasiertes FastSLAM . . . 20
3.6.2 FastSLAM 2.0 . . . 22
3.7 Datenassoziation bei unbekannter Korrespondenz . . . 24

4 Simulationsumgebung **27**
4.1 Zweidimensionales Umgebungsmodell . . . 27
4.2 Physikalisches Robotermodell . . . 27
4.3 Eindimensionale Bildmessung . . . 29

5 Detektion, Beschreibung und Verfolgung von Bildmerkmalen **31**
5.1 Merkmalsdetektion in Ort und Skala . . . 31
5.2 Effiziente Mehrskalenrepräsentation . . . 33
5.3 Detektion punktförmiger Merkmale . . . 36
5.3.1 Kantendetektion . . . 37
5.3.2 Blobdetektion . . . 39
5.4 Beschreibung punktförmiger Merkmale . . . 41
5.4.1 Kantenbeschreibung . . . 42
5.4.2 Blobbeschreibung . . . 43
5.5 Verfolgung von Merkmalen in Bildsequenzen . . . 43

6 Simultanes Lokalisieren und Kartieren mit visuellen Landmarken **45**
6.1 Bewegungsmodell des Roboters . . . 45
6.2 Beschreibung und Observation von Landmarken . . . 46
6.2.1 Kartesische Parametrisierung . . . 47
6.2.2 Inverse Tiefenparametrisierung . . . 47

6.2.3 Eigenschaften der Parametrisierungsformen 47
6.3 Simultane Schätzung von Trajektorie und Karte 50
6.4 Initiale Posenschätzung 52
6.5 Assoziation von Landmarken mit Bildmerkmalen 52
6.5.1 Datenassoziation durch Merkmalsverfolgung 54
6.5.2 Modellgetriebene Datenassoziation 55
6.6 Robuste Posenkorrektur und Ziehen von Partikelposen 57
6.7 Partikelgewichtung 58
6.8 Kartenaktualisierung 58
6.8.1 Initialisierung von Landmarken 59
6.8.2 Rekursive Landmarkenpositionsschätzung 59
6.8.3 Detektionsrate und erwartete Sichtbarkeit 60
6.8.4 Wechsel der Landmarkenparametrisierung 61
6.8.5 Deskriptorschätzung 61
6.8.6 Entfernen von Landmarken 62
6.9 Erneuerung der Partikelmenge 63

7 Erzeugung und Verwendung eines Wandmodells 65
7.1 Probabilistische Beschreibung von Wänden 65
7.2 Observation und Existenz von Wänden 67
7.3 Bestimmung der sichtbaren Wandsegmente 71
7.4 Verbesserung des Kartierens von Landmarken durch Wände 72
7.4.1 Tiefeninitialisierung 72
7.4.2 Datenassoziation 73
7.4.3 Erwartete Sichtbarkeit 74
7.5 Hauptorientierung der Umgebung 74
7.5.1 Bestimmung der Hauptorientierung 75
7.5.2 Verwendung für die Existenzschätzung von Wänden 77
7.5.3 Registrierung des Wandmodells mit der Hauptorientierung 77

8 Verwendung in einem realen Szenario 79
8.1 Kamera- und Linsenverzerrungsmodell 79
8.2 Segmentierung des Fussbodens 80
8.3 Tiefenschätzung am Fussbodensegment 81
8.4 Extraktion eines Zeilenbilds 84
8.5 Verwendung von Tiefenmessungen im SLAM-Verfahren 84
8.5.1 Erweitertes Landmarkenobservationsmodell 85
8.5.2 Tiefeninitialisierung von Landmarken 85
8.5.3 Erweiterte Datenassoziation 85
8.5.4 Erweiterte Existenzschätzung von Wänden 86
8.5.5 Observation und Korrektur von Wänden durch Tiefe 88
8.5.6 Extraktion und Verwendung von Tiefenmerkmalen 89
8.6 Bewegungsschätzung 90
8.6.1 Bewegungsinformation aus einem Inertialsensor 91
8.6.2 Bewegungsinformation aus Tiefenmessungen 91
8.6.3 Fusion der Bewegungsinformationen 94
8.6.4 Posenkorrektur durch Tiefenbildregistrierung 95

9 Experimentelle Ergebnisse **97**
9.1 Experimente in der Simulationsumgebung 97
9.1.1 Kartieren bei bekannter Pose 97
9.1.2 Simultanes Lokalisieren und Kartieren 101
9.2 Experimente in der realen Umgebung 109
9.2.1 Evaluation der Bewegungsschätzung 110
9.2.2 Simultanes Lokalisieren und Kartieren 111
9.2.3 Globale Lokalisierung 115

10 Zusammenfassung **121**
10.1 Beiträge dieser Arbeit 122
10.2 Diskussion 123
10.3 Ausblick 124

A Verwendete Hardware **131**
A.1 Kamera mit Weitwinkelobjektiv 131
A.2 Inertialsensor 131

B Extraktion von Tiefenmerkmalen **133**

1 Einleitung

Innerhalb eines halben Jahrhunderts haben Computer unseren Alltag durchdrungen und sich vom wissenschaftlichen Werkzeug zu einem unverzichtbaren Antrieb von Wirtschaft, Wissenschaft und Gesellschaft entwickelt. Ein aktueller Trend hin zu immer komplexeren und intelligenteren Anwendungen ist unverkennbar. Dabei wandelt sich das passive Werkzeug Computer zum zentralen Element von Systemen, die autonom in ihrer Umwelt agieren. Mobile autonome Systeme werden seit einigen Jahrzehnten erforscht und besitzen das Potential, in einigen Jahren in breiter Form Verwendung zu finden. Bereits heute werden Erkundungsroboter in unzugänglichen, überlebensfeindlichen Umgebungen wie Weltraum, Tiefsee oder Minen eingesetzt. Dienstleistungsroboter saugen Fussböden, mähen Rasen oder verteilen Medikamente in Krankenhäusern, und Militär- und Rettungsroboter werden zur Aufklärung in Situationen eingesetzt, die für Menschen lebensgefährlich sind.

Für den erfolgreichen Einsatz eines autonomen mobilen Systems in seiner Umwelt ist eine Vielzahl von Fähigkeiten nötig. Eine grundlegende Voraussetzung eines Roboters zur Navigation und autonomen Ausführung von Aufgaben ist es, sich in seiner Arbeitsumgebung zu orientieren. Ist zuvor keine Karte der Umgebung bekannt, ergibt sich eine besondere Schwierigkeit. Während das System seine Umgebung kartiert, muss es seinen Ort in der Umgebung kennen. Diesen Ort kann das System jedoch nur bezüglich einer korrekten Karte anhand seiner Beobachtungen ableiten.

In den vergangenen Jahren wurden effiziente und robuste Methoden zur Lösung dieses Problems des simultanen Lokalisierens und Kartierens (SLAM, aus dem englischen: Simultaneous Localization and Mapping) entwickelt, unterstützt vor allem durch die Verwendung probabilistischer Ansätze. Die Umgebung kann in diesen Verfahren in unterschiedlichen Weisen repräsentiert werden. Metrische Repräsentationen stellen Karten als Mengen von Landmarken oder diskretisiert in Gitterkarten dar und ermöglichen es, den Ort des Roboters metrisch akkurat zu bestimmen. Topologische Karten repräsentieren die Umgebung qualitativ. Sie setzen sich aus einer Menge von wiedererkennbaren Orten zusammen, deren Erreichbarkeit in Graphen dargestellt wird. Das eingesetzte SLAM-Verfahren und die verwendete Kartenrepräsentation sind anwendungsspezifisch und sind stark durch die Sensorik des Roboters und die Gestalt der Umgebung bestimmt.

Mit Laser-Entfernungssensoren können beeindruckend akkurate Ergebnisse erzielt werden, da sie präzise Messungen in einem weiten Blickwinkelbereich liefern. Die Nachteile solcher Sensoren liegen in Gewicht, Kosten und Stromverbrauch. Eine kostengünstige und gewichtsmässig leichte Alternative sind Kameras, die in mobilen Geräten und vielen kommerziellen Roboterplattformen verfügbar sind. Die Schwierigkeiten bei der Verwendung einer Kamera liegen in der Notwendigkeit, die reichhaltige Information eines Bildes effizient zu interpretieren, und in der Tatsache, dass Tiefe aufgrund der projektiven Natur der Bildaufnahme in einem einzelnen Bild nicht observierbar ist, falls keine weiteren Annahmen über die abgebildete Szenerie getroffen werden. Stattdessen muss sie aus Bewegungsparallaxe geschätzt oder durch die Verwendung eines Mehrkamerasystems erfasst werden.

Abbildung 1.1: Parallele und orthogonale Wände sind funktional und erleichtern visuelle Orientierung in Innenräumen. Das rechte Bild illustriert die Ungewöhnlichkeit von Abweichungen von dieser Norm.

Trotz dieser Schwierigkeiten orientieren sich Menschen hauptsächlich visuell in ihrer Umgebung. Insbesondere Innenräume werden daher häufig für diesen Zweck speziell eingerichtet, indem beispielsweise Objekte farblich unterscheidbar gestaltet werden. Zudem bieten Parallelität und Orthogonalität von Wänden eine klare Struktur, in der visuelle Orientierung erleichtert wird. Beschränkt sich das Anwendungsgebiet eines Roboters auf Innenräume, liegt es nahe, visuelle Sensoren zu verwenden und die besonderen Eigenschaften solcher Umgebungen auszunutzen.

1.1 Zielsetzung

Im Rahmen dieser Arbeit soll das Problem des simultanen Lokalisierens und Kartierens in Innenräumen mit einer einzelnen Kamera betrachtet werden. Die Kartenrepräsentation soll die Wandstruktur der Umgebung modellieren, sodass eine abstraktere Darstellung für Navigation und Lokalisation entsteht als bei der Verwendung von punktbasierten Landmarkenkarten. Es sollen Techniken entwickelt werden, die typische Eigenschaften von Innenräumen zur Verbesserung des SLAM-Verfahrens ausnutzen. Das Problem wird auf die Erstellung von zweidimensionalen Karten beschränkt, während sich die Kamera in der horizontalen Ebene bewegt.

Es werden grundlegende Annahmen über die typischen Eigenschaften der Umgebung getroffen:

- Die Umgebung besteht aus planaren Flächen (Fussboden, Decke und Wände).
- Die planaren Flächen sind entweder parallel oder stehen orthogonal aufeinander.

1.2 Aufbau dieser Arbeit

Zunächst geben wir in Kapitel 2 einen Überblick über verwandte Arbeiten. Anschließend legen wir in Kapitel 3 die theoretischen Grundlagen dieser Arbeit aus dem Gebiet der probabilistischen Robotik dar. Der vorgeschlagene Ansatz wird in einer zweidimensionalen Umgebungssimulation entwickelt und evaluiert, die wir in Kapitel 4 vorstellen. Das folgende Kapitel 5 beschäftigt sich mit Detektion, Beschreibung und Verfolgung von Bildmerkmalen in Sequenzen eindimensionaler Bilder. Diese Bildmerkmale werden als Obser-

vationen von punktförmigen Landmarken aufgefasst. Das SLAM-Verfahren für die rekursive Schätzung der Position dieser Landmarken und der Pose des Roboters[1] stellen wir in Kapitel 6 vor. Anhand der Landmarkenobservationen und -schätzungen generieren wir ein Wandmodell in Kapitel 7, und erläutern dessen Verwendung zur Verbesserung und Erweiterung des SLAM-Verfahrens. Anschliessend wird das Verfahren in Kapitel 8 für die Verwendung in einem realen Szenario um Tiefenmessungen am Fussbodensegment und eine Methode zur visuellen Bewegungsschätzung unter Verwendung eines Inertialsensors erweitert. In Kapitel 9 evaluieren wir das vorgestellte Verfahren in der Simulation und in einer realen Beispielumgebung, die den getroffenen Annahmen über die Arbeitsumgebung ausreichend genügt. Zusammenfassung und Diskussion des vorgestellten Ansatzes finden sich in Kapitel 10.

[1] Da es sich bei der Zielplattform des Verfahrens um einen Roboter handelt, werden in dieser Arbeit die Begriffe Roboter und Kamera gleichbedeutend verwendet.

2 Verwandte Arbeiten

In den vergangenen Jahren wurde eine Reihe von Ansätzen vorgestellt, die das simultane Lokalisieren und Kartieren mit visuellen Sensoren ermöglichen. Eine Vielzahl der Verfahren verwendet punktbasierte Merkmale als Observationen von Landmarken. Insbesondere die Skaleninvariante Merkmalstransformation (SIFT, aus dem englischen: Scale-invariant feature transform) [1] in Kombination mit einem diskriminativen Deskriptor bietet eine effiziente Möglichkeit, stabile punktförmige Merkmale aus Graustufen-Bildern zu extrahieren, die gut lokalisierbaren Punkten in der Umgebung entsprechen.

Se et al. [2] erzeugen Karten von SIFT-Merkmalen mit einem Stereosichtsystem, indem die dreidimensionalen Positionen der Landmarken im Weltkoordinatensystem durch erweiterte Kalmanfilter [3] geschätzt werden. Odometrie der Roboterplattform wird dazu verwendet, modellgetrieben Suchregionen für Korrespondenzen von Bildmerkmalen zu Landmarken in der Karte zu bestimmen. Mit Hilfe der hergestellten Korrespondenzen wird die Bewegung des Roboters durch Gradientenabstieg bestimmt, sodass die Projektion der Landmarkenpositionen in das Bild mit den Bildorten der korrespondierenden Merkmalen bestmöglich übereinstimmt. In diesem Ansatz werden keine Korrelationen zwischen Posenschätzung und Karte aufrechterhalten, sodass das Schliessen von grossen Trajektorienschleifen problematisch ist.

Barfoot [4] stellt ein Verfahren vor, das Pose des Roboters und Positionen von SIFT-Landmarken in einem FastSLAM 2.0 Verfahren [5] schätzt. Tiefe und Winkel zu SIFT-Merkmalen werden auch hier mit Hilfe eines Stereosichtsystems ermittelt. Zur Bewegungsschätzung wird Odometrie des Roboters verwendet. Aus Effizienzgründen kann das Partikelfilterverfahren nur mit einem einzigen Partikel betrieben werden, sodass auch in diesem Verfahren Korrelationen zwischen Posenschätzung und Karte nicht berücksichtigt werden. Experimente zeigen, dass die Trajektorie des Roboters sowohl im Aussenbereich als auch in Innenräumen in ausreichender Qualität geschätzt werden kann.

Sim et al. [6] präsentieren ein System, das visuelle Information und Odometrie in unterschiedlichen Konfigurationen mit Rao-Blackwellisierten Partikelfilterverfahren verarbeiten kann. Es unterstützt sowohl die Verarbeitung von Winkel- und Tiefenmessungen eines Stereosichtsystems als auch die Kombination aus Odometrie und reinen Winkelobservationen einer einzelnen Kamera. Die Pose des Roboters wird in diesem System als sechsdimensionale Position und Lage im Raum dargestellt. Auch dieses System verwendet SIFT-Merkmale als Observationen von Landmarken. Die Autoren berichten Echtzeitfähigkeit des Systems mit 100 Partikeln bei Karten mit bis zu 200.000 Landmarken. Das Verfahren ist zudem in der Lage, unter Verwendung eines Stereosichtsystems Belegtheitskarten zu erstellen, die gerade für die Navigation und Pfadplanung nützlich sind [7].

Das kommerzielle vSLAM-System [8] verwendet ebenfalls SIFT-Merkmale. Allerdings werden Merkmale hier nicht als Observationen punktförmiger Landmarken in der Karte aufgefasst, sondern Landmarken sind eine dreidimensionale Anordnung von SIFT-Merkmalen im Koordinatensystem eines Bildes, deren relative 3D-Positionen in drei Folgebildern mit ausreichend grossem Kameraabstand bestimmt wurden [9]. Eine Karte besteht aus

erweiterten Kalmanfilter-Schätzungen der globalen Position dieser Landmarken. Karte und Trajektorie des Roboters werden in einem FastSLAM-Partikelfilterverfahren [10] geschätzt, wobei die Pose des Roboter auf Position und Orientierung in der Horizontalen eingeschränkt ist.

Die Vorzüge von SIFT-Merkmalen zur zuverlässigen und konsistenten Lösung des SLAM-Problems sind Invarianz gegenüber einer Vielzahl von Transformationen und hohe Diskriminierbarkeit. Für die Navigation sind jedoch Kartenrepäsentationen nützlich, die die Umgebung semantisch höherwertig darstellen als in punktbasierten Landmarken ohne Ausdehnung und Bedeutung in der Umgebung. Die vorgestellten Ansätze sind darauf ausgelegt, robuste und exakte metrische Lokalisation in zur Laufzeit akquirierten Karten zu ermöglichen.

Ein weitere Ansatz, der nicht auf SIFT-ähnlichen Merkmalen beruht, wurde von Davison et al. [11] vorgestellt. Das Verfahren verwendet ebenfalls punktbasierte Merkmale. Zur ersten Detektion der Merkmale wird der Interessantheitsoperator von Shi und Tomasi [12] verwendet, der auch als KLT-Detektor bekannt ist. An diesen Bildorten werden Bildausschnitte der Pixelgrösse 11×11 zur Beschreibung der erzeugten Landmarken verwendet, deren Ausrichtungen orthogonal zur Sichtlinie zum ersten detektierten Bildort angenommen wird. Da die Bewegung der Kamera geschätzt wird, kann der erwartete Ort einer Landmarke unter Berücksichtigung ihrer Unsicherheit im Bild modellgetrieben bestimmt werden. Ebenfalls kann die projektive Verzerrung des Bildausschnittes einer Landmarke berechnet werden. Dadurch ist die Suche nach einem Merkmal durch Abgleich mit dem Prototypen auf einen kleinen Bildbereich eingeschränkt. Das Verfahren verwendet eine einzelne Kamera, um die sechsdimensionale Pose und die dreidimensionalen Positionen von Landmarken in einem EKF-SLAM-Ansatz bei einer Bildrate von 30 Hz zu schätzen. Odometrie wird nicht verwendet, allerdings muss die metrische Skala durch eine vorinitialisierte Karte vorgegeben werden, indem das Verfahren mit einer bekannten Struktur im Sichtfeld der Kamera gestartet wird. Der EKF-Ansatz schränkt die Anzahl an verwaltbaren Landmarken auf bis zu hundert ein, da der Laufzeitaufwand quadratisch in der Landmarkenzahl ist.

Unter Verwendung einer einzelnen Kamera ist die Tiefe von Landmarken nur durch Bewegungsparallaxe observierbar, sodass die Tiefe bei der Initialisierung der Positionsschätzung mit hoher Unsicherheit modelliert werden muss. In der ursprünglichen Form des Verfahrens wurden Landmarkenpositionsschätzungen verzögert initialisiert, indem die initiale Tiefe für das EKF-Verfahren entlang der Sichtlinie der ersten Sichtung durch separate Partikelfilter ermittelt wird, bis die Tiefenschätzung ausreichend normalverteilt ist. Montiel et al. [13] erweiterten den Ansatz um eine unverzögerte Initialiserungsmethode. Durch die Darstellung der normalverteilten Landmarkenpositionsschätzung in inverser Tiefe ist das Observationsmodell von reinen Winkeln auch für hohe Unsicherheiten in der Tiefe linear.

Eade et al. [14] modifizieren Davisons Ansatz, indem anstelle des EKF ein FastSLAM 2.0 Verfahren verwendet wird, um Trajektorie und Karte zu schätzen. Landmarken werden ebenfalls in inverser Tiefe initialisiert und bei hinreichender Sicherheit in der Schätzung in die kartesische Parametrisierung umgewandelt. Das Verfahren ist echtzeitfähig für 50 Partikel bei einer Kartengrösse von 250 Landmarken und 20-30 Observationen pro Bild. Die verwendete Bildrate beträgt 30 Hz.

Diese Verfahren erzeugen ebenfalls Karten punktbasierter Landmarken. Für EKF- und partikelfilterbasierten Ansatz wurden jeweils Erweiterungen vorgestellt [15, 16], die zusät-

zlich zu punktbasierten Merkmalen semantisch höherwertigere Linienmerkmale verwenden. Dennoch ist insbesondere der EKF-basierte Ansatz auf die Lokalisation der Kamera ausgelegt. Neue Landmarken werden nur dann in die Karte aufgenommen, falls die Anzahl der observierten Landmarken klein ist. Eine abstrakte und vollstände Repräsentation der Umgebung ist nicht beabsichtigt.

Autonome mobile Systeme, die in Innenräumen eingesetzt werden, sind typischerweise in ihrer Bewegung auf die horizontale Ebene beschränkt. Zudem bestehen Innenräume aus Strukturen, die in der Horizontalen beschrieben werden können. Beispiele für Methoden dieser Art sind Verfahren, die zweidimensionale Karten mit 2D-Lasersensoren erstellen. Analog ist es möglich, zweidimensionale Bilder zu eindimensionalen Observationen zu komprimieren und die Umgebung zweidimensional zu repräsentieren.

Briggs et al. [17] stellen ein Verfahren vor, das eindimensionale Zeilenbilder einer omnidirektionalen Kamera verwendet, um den Roboter relativ zu einer Menge von Referenzbildern metrisch zu lokalisieren. In einem eingeschränkten Winkelbereich um die Horizontale wird ein mittleres Zeilenbild erzeugt. Skaleninvariante Merkmale in diesen Bildern [18] werden durch die lokale Gestalt des Skalenraums und durch Helligkeits- und Farbwerte beschrieben. Die typische Anzahl an detektierten Merkmalen in einem Bild liegt bei 400-600. Aus der Merkmalskorrespondenz in zwei Bildern, die in einem effizienten Zuordnungsverfahren bestimmt wird [19], kann die relative Bewegung des Roboters zwischen den Bildern ermittelt werden. Eine Karte zur Navigation wird erstellt, indem in bekannten Positionen Referenzbilder für unterschiedliche Beleuchtungssituationen gespeichert werden. Die Pose des Roboters wird bestimmt, indem eine Menge von Zuordnungen des aktuell observierten Bildes zu Referenzbildern in der Karte hergestellt wird. Ist eine initiale Schätzung der Pose des Roboters bekannt, muss nicht die gesamte Menge an Referenzbildern betrachtet werden. Die Pose des Roboters ergibt sich durch gewichtete Mittelung der ermittelten relativen Bewegungen aus den zugeordneten Bildern. Zur Gewichtung wird die Kompatibilität der Bildzuordnung verwendet. Für die Navigation in dieser Kartenrepräsentation werden die Orte, in denen Referenzbilder aufgezeichnet wurden, als Knoten eines Sichtbarkeitsgraphen aufgefasst. Knoten kompatibler Referenzbilder in diesem Graphen werden durch Kanten verbunden, sodass darin Pfade geplant werden können. Auch dieser Ansatz erzeugt keine geometrische Umgebungsrepräsentation, in der räumliche Zusammenhänge erschlossen werden können. Der traversierbare Bereich ist durch die Kompatibilitätsbeziehungen der Referenzbilder festgelegt. Im Vergleich zur vorliegenden Arbeit ist der Ansatz topologisch und löst Lokalisation und Kartierung nicht simultan.

In einem einzelnen Bild ist Tiefe nicht observierbar. Die typischen Eigenschaften von Innenräumen können jedoch ausgenutzt werden, um Tiefe in einem Bild abzuleiten. Sogenannte visuelle Sonar-Methoden extrahieren Tiefe zu Objekten am Übergang des Fussbodens zu den Objekten.

Im Ansatz von Lenser et al. [20] werden Linien im Bild verfolgt, die ausgehend von der Position des Roboters in diskreten Abtastwinkeln entlang der Fussbodenebene verlaufen. Hindernisse und Objekte werden entlang dieser Linien detektiert, falls eine signifikante Anzahl an aufeinanderfolgenden Pixeln nicht der Klasse der Fussbodenfarbe angehört. Die Farbklassenzugehörigkeit der Bildpixel wird in einem Vorverarbeitungsschritt bestimmt. Die Distanz zu detektierten Objekten ergibt sich als Entfernung des Roboters zum Schnittpunkts der Sichtlinie zum Objekt mit der Fussbodenebene. Diese Tiefeninformation wird zur Hindernisvermeidung verwendet.

Choi et al. [21] extrahieren Tiefeninformation zu Hindernissen und Objekten in einer typischen Büroumgebung auf einer mobilen Plattform, die sich in der horizontalen Ebene bewegt und mit einer Kamera ausgestattet ist. Die Fussbodenfarbe wird durch eine Histogrammmethode innerhalb eines Bildausschnitts bestimmt, der den Bereich in direkter Nähe des Roboters enthält. Mit diesen Tiefeninformationen werden zunächst Belegtheitskarten erzeugt. Anschliessend werden diese Karten zur partikelfilterbasierten Lokalisation verwendet.

Eine weitere typische Eigenschaft von Innenräumen ist die Parallelität bzw. Orthogonalität von Wänden. Im OrthoSLAM-Verfahren [22] wird diese Tatsache ausgenutzt. Es werden Linien kartiert, die aus Entfernungsmessungen eines 2D-Laserscanners extrahiert werden und zur Hauptrichtung der Umgebung parallel oder orthogonal sind. In der Tiefenmessung wird eine Referenzorientierung bestimmt, auf die die extrahierten Liniensegmente registriert werden. Die Karte wird in relativen Abständen zwischen horizontalen und vertikalen Liniensegmenten in der Umgebung dargestellt. Die relative Darstellung ist daher invariant zur Pose des Roboters. Diese Abstände können für beide Hauptrichtungen separat in linearen, eindimensionalen Kalmanfiltern geschätzt werden, indem Korrelationen zwischen den Kartenelementen vernachlässigt werden. Um eine absolute Karte zu erhalten, ist lediglich die Kenntnis der globalen Position eines einzigen Liniensegments notwendig. Die Assoziation von kartierten Liniensegmenten mit aktuellen Observationen wird im wesentlichen durch die Bestimmung des nächsten kompatiblen Nachbarn bewerkstelligt. Die Vorhersage der aktuellen Pose des Roboters aus der Odometrie wird verwendet, um den Ort der Observationen im globalen Koordinatensystem zu ermitteln. Nach der Kartenaktualisierung wird die aktuelle Pose des Roboters deterministisch bestimmt, sodass die Observation mit der Karte bestmöglich übereinstimmt. Das Verfahren besitzt lineare Laufzeit in der Anzahl der Liniensegmente in der Karte und ist in der Lage eine Umgebung der Grösse 80m×50m mit einer Trajektorie der Länge 500m in Echtzeit und einer metrischen Genauigkeit von 99.7% zu kartieren.

Jensfelt et al. [23] nutzen ebenfalls die typische parallele und orthogonale Struktur in Innenräumen aus. Tiefenmessungen werden dazu verwendet, die Odometrie eines autonomen Systems zu korrigieren. Unter der Annahme, dass Strukturen der Umgebung parallel oder orthogonal in der Tiefenmessung erscheinen, werden geometrische Bedingungen in den Tiefenmessungen durch Anpassung der Posenschätzung durchgesetzt. Das Verfahren findet in einem kommerziellen Staubsaugerroboter Verwendung, der mittels Odometrie und Ultraschallsensorik Wänden folgt, um die Umrisse der Umgebung zu erfassen.

In dieser Arbeit sollen ebenfalls die typischen Eigenschaften der Umgebung ausgenutzt werden. Im Gegensatz zu den vorgestellten Verfahren stehen visuelle Informationen einer einzelnen Kamera zur Verfügung, mit denen simultan die Pose des Roboters und eine Karte der Umgebung geschätzt werden sollen.

3 Grundlagen

Die Bestimmung der Pose eines Roboters und das gleichzeitge Lernen einer Karte der Umgebung ist eines der zentralen Probleme in der Robotik. Typischerweise stehen dem System zur Schätzung seines Zustandes Informationen über selbst ausgeführte Aktionen und Messungen der Umgebung durch geeignete Sensoren zur Verfügung. In einer realen Anwendung sind diese Informationen allerdings mit Unsicherheiten behaftet. Weder ist es möglich, Auswirkungen von Aktionen unter allen möglichen Einflüssen deterministisch zu modellieren, noch kann von einem Sensor angenommen werden, dass seine Messungen exakt sind. In der probabilistischen Robotik befasst man sich daher mit der Modellierung und Propagation dieser Unsicherheiten für die robuste Zustandsschätzung von Roboter und Karte.

Eine wichtige Anforderung besteht darin, bereits während des Betriebs zu einer robusten Zustandsschätzung zu gelangen. Hierfür werden rekursive Verfahren zur Zustandsschätzung benötigt. Im folgenden werden die Grundlagen für die rekursive, probabilistische Zustandsschätzung aus unsicheren Ergebnissen von Aktionsausführungen und Observationen vorgestellt.

3.1 Systemgrößen

Die Pose s_t des Roboters beschreibt die globale Position und Orientierung des Roboters in seiner Umgebung in diskreten Zeitpunkten t. In dieser Arbeit wird angenommen, dass sich der Roboter lediglich in einer Ebene bewegt, sodass die Pose durch kartesische Koordinaten x_t, y_t und Orientierung θ_t darstellen lässt, d.h.

$$s_t := (x_t, y_t, \theta_t)^T$$

Durch die Ausführung von Aktionen kann der Zustand des Roboters oder seiner Umgebung manipuliert werden. Die Kontrolleingabe u_t liefert Aufschluß über die Auswirkungen der zum Zeitpunkt t ausgeführten Aktion und besteht beispielsweise aus Zielgeschwindigkeiten, Gelenkstellungen, oder auch Odometriedaten. Letztere sind zwar im eigentlichen Sinne Messungen eines Sensors, werden aber als Maß für die Auswirkung von Aktionen interpretiert und gleichwertig als Kontrolleingaben verwendet.

Zusätzlich zu den Effekten seiner Aktionen, nimmt der Roboter seine Umgebung durch Sensoren wahr, deren Messung zum Zeitpunkt t wir als Observation z_t notieren. Laser-Entfernungssensoren messen beispielsweise Entfernung und Winkel zu einem zurückreflektierenden Objekt, während Kamerabilder aufgrund ihrer Reichhaltigkeit an Pixel- und Farbinformation nicht direkt als Observation aufgefasst werden. Die in Bildern enthaltene Information muss daher geeignet zusammengefasst werden. Beispielsweise können Merkmale extrahiert werden, deren Beschreibungen und Sichtwinkel bezüglich des Aufnahmeortes als Messungen zur Verfügung stehen.

Abhängig von der Natur der Messungen werden Karten gitter- oder landmarkenbasiert dargestellt. In dieser Arbeit verwenden wir Bildmerkmale als Observationen von Landmarken. Die statische Karte $m := \{L_j\}_{j=1}^{N}$ besteht demnach aus N Landmarken an den Positionen l_j. In vielen Anwendungen sind die Positionsschätzungen der Landmarken normalverteilt in kartesischen Koordinaten parametrisiert.

3.2 Probabilistische Zustandsschätzung

Die zeitlich diskrete Entwicklung von Zuständen und Observationen unter dem Einfluß der gewählten Aktionen ist ein stochastischer Prozess, der als dynamisches Bayessches Netzwerk (Abb.3.1) dargestellt werden kann. Dabei wird in jedem Zustand x_{t-1} zunächst eine Aktion mit Kontrolleingabe u_t ausgeführt, die das System in den Zustand x_t überführt. Im neuen Zustand x_t steht schließlich eine Observation z_t des aktuellen Zustands zur Verfügung.

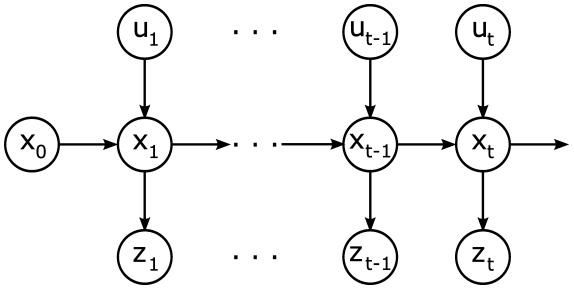

Abbildung 3.1: Darstellung der probabilistischen Zustandsschätzung als dynamisches Bayessches Netzwerk. Zu jedem Zeitpunkt t wird der verborgene Zustand x_t durch die Observation z_t beobachtet. Kontrolleingaben u_t wirken auf den Zustandsübergang von x_{t-1} nach x_t.

Der Zustand des Sytems ist nicht direkt erfassbar. Stattdessen muss er aus den bisherigen nichtdeterministischen Aktionen und fehlerbehafteten Observationen geschätzt werden. Diese Zustandsschätzung wird als Wahrscheinlichkeitsverteilungsdichte

$$bel(x_t) := p(x_t|z_{1:t}, u_{1:t})$$

über aktuelle Zustände x_t des Systems bei gegebener vollständiger Historie an Observationen $z_{1:t}$ und Aktionen $u_{1:t}$ formuliert. Dabei verwenden wir die Notation $x_{1:t} := x_1, \ldots, x_t$.

Die unsichere Auswirkung von Aktionen beschreibt das Zustandübergangsmodell. Es ist definiert als Verteilungsdichte

$$p(x_t|x_{t-1}, u_t)$$

über Zustände x_t bei gegebenem Vorgängerzustand x_{t-1} und bekannter Kontrolleingabe u_t.

Diese Darstellung ist unter den Markowschen Annahmen gerechtfertigt, dass eine Aktion lediglich den aktuellen Zustand beeinflußt, und dass die Zustandsbeschreibung vollständig ist. Eine vollständige Zustandsbeschreibung beinhaltet alle verfügbaren Informationen, um zukünftige Zustände vorherzusagen. Das bedeutet, dass vergangene Zustände, Aktionen und Observationen keinen Informationsgewinn liefern. Der Zustand x_t ist also

stochastisch unabhängig von $x_{0:t-2}$, $z_{1:t-1}$ und $u_{1:t-1}$, falls x_{t-1} und u_t gegeben sind, d.h.

$$p(x_t|x_{0:t-1}, z_{1:t-1}, u_{1:t}) = p(x_t|x_{t-1}, u_t).$$

Die Observation z_t ist eine Abbildung des aktuellen Zustand x_t. Diese kausale Abhängigkeit führt zum probabilistischen Observationsmodell

$$p(z_t|x_t).$$

Auch für das Observationsmodell liefert die Markowsche Annahme der vollständigen Zustandsbeschreibung eine wichtige bedingte stochastische Unabhängigkeit: Ist der aktuelle Zustand x_t gegeben, ist die Observation z_t stochastisch unabhängig von den Zuständen $x_{0:t-1}$, den Observationen $z_{1:t-1}$ und den Kontrolleingaben $u_{1:t}$:

$$p(z_t|x_{0:t}, z_{1:t-1}, u_{1:t}) = p(z_t|x_t)$$

In der Bedeutung von Kontrolleingaben und Observationen für die Zustandsschätzung besteht ein wesentlicher Unterschied: Kontrolleingaben erhöhen aufgrund des unsicheren Ergebnisses einer Aktionsausführung die Unsicherheit in der Zustandsschätzung, während Observationen Informationen über den Zustand tragen, wodurch die Unsicherheit reduziert werden kann.

3.3 Rekursive Bayessche Filter

Die Schätzung der Verteilungsdichte des aktuellen Zustands, $bel(x_t)$, lässt sich mit Hilfe der getroffenen Markowschen Annahmen und der Bayesschen Regel rekursiv formulieren:

$$\begin{aligned} bel(x_t) &= p(x_t|z_{1:t}, u_{1:t}) \\ &= \dots \\ &= \eta\ p(z_t|x_t) \int p(x_t|x_{t-1}, u_t)\ bel(x_{t-1})\ dx_{t-1}, \end{aligned} \tag{3.1}$$

wobei $bel(x_0) = p(x_0)$ die initiale Zustandsschätzung darstellt, mit der Vorwissen in das Filter eingebracht werden muss.

Der innere Term dieser Rekursion wird als Vorhersage

$$\overline{bel}(x_t) = \int p(x_t|x_{t-1}, u_t)\ bel(x_{t-1})\ dx_{t-1}$$

des aktuellen Zustands x_t bezeichnet, in der die Zustandsüberführung aus dem vergangenen Zustand x_{t-1} durch die Kontrolleingabe u_t berücksichtigt wird. Die Korrektur bezeichnet die Einbeziehung der aktuellen Observation z_t in die Vorhersage $\overline{bel}(x_t)$ zur Zustandsschätzung

$$bel(x_t) = \eta\ p(z_t|x_t)\ \overline{bel}(x_t).$$

Um diese allgemeine rekursive Formulierung zu implementieren, stehen unterschiedliche Filtermethoden zur Verfügung. Einerseits kann die Zustandsschätzung parametrisch dargestellt werden, indem Annahmen über die zugrundeliegende Form der Wahrscheinlichkeitsverteilung des Zustandes getroffen werden. Nichtparametrische Filter hingegen legen sich nicht auf eine bestimmte Form der Wahrscheinlichkeitsverteilung fest. Stattdessen wird der Zustandsraum geeignet diskretisiert und die Zustandsschätzung als Verbundverteilung über die diskretisierten Zustände aufgefasst. Im folgenden werden wir Filtermethoden vorstellen, die in dieser Arbeit Verwendung finden.

3.3.1 Das erweiterte Kalmanfilter

Das Kalmanfilter (KF) [24] ist eine parametrische Variante des rekursiven Bayesschen Filters, das den Systemzustand x_t normalverteilt mit Parametern (μ_t, Σ_t) schätzt. In der grundlegenden Form wird angenommen, dass Zustandsübergangs- und Beobachtungsmodell linear dargestellt werden können und mit normalverteiltem Rauschen behaftet sind.

Das lineare Zustandsübergangsmodell

$$x_t = A_t x_{t-1} + B_t u_t + \epsilon_t$$

beschreibt den Übergang des Zustands x_{t-1} in den Zustand x_t. Nach einem Zeitschritt wird der Zustand x_{t-1} zunächst linear in $A_t x_{t-1}$ abgebildet. Die Kontrolleingabe wirkt additiv durch die lineare Kontrollmatrix B_t auf den Zustand. Der Fehler in diesem Zustandsübergang wird als additive, normalverteilte Komponente $\epsilon_t \sim \mathcal{N}(0; R_t)$ modelliert.

Das Beobachtungsmodell erklärt die Messung als lineare Abbildung des Zustands

$$z_t = C_t x_t + \delta_t$$

mit normalverteiltem Fehler $\delta_t \sim \mathcal{N}(0; Q_t)$.

Aufgrund der normalverteilten Parametrisierung muss auch die Schätzung des initialen Zustands normalverteilt gewählt werden. Im aktuellen Zeitschritt t werden nun aus Kontrolleingabe u_t und Beobachtung z_t die Vorhersage und Korrektur der letzten Schätzung $(\mu_{t-1}, \Sigma_{t-1})$ bestimmt. Die Eigenschaft normalverteilter Variablen unter linearen Transformationen wiederum normalverteilt zu sein, macht eine exakte Lösung möglich. Eine detaillierte Herleitung des Verfahrens findet sich in [25].

Die Vorhersage

$$\begin{aligned} \overline{\mu}_t &= A_t \mu_{t-1} + B_t u_t \\ \overline{\Sigma}_t &= A_t \Sigma_{t-1} A_t^T + R_t \end{aligned}$$

bildet den Mittelwert μ_{t-1} der letzten Schätzung auf den vorhergesagten Mittelwert $\overline{\mu}_t$ durch die Anwendung des Zustandübergangsmodells ab. Die Kovarianz der Zustandsschätzung Σ_{t-1} wird aufgrund des linearen Zustandübergangs in $A_t \Sigma_{t-1} A_t^T$ transformiert und um die Kovarianz des additiven Rauschens R_t vergrößert.

Der Fehler $\Delta z_t := z_t - C_t \overline{\mu}_t$ zwischen tatsächlicher und erwarteter Messung wird als Innovation bezeichnet. Mit der Innovation und der Kalman-Verstärkung

$$K_t = \overline{\Sigma}_t C_t^T (C_t \overline{\Sigma}_t C_t^T + Q_t)^{-1}$$

wird die Vorhersage korrigiert:

$$\begin{aligned} \mu_t &= \overline{\mu}_t + K_t \Delta z_t \\ \Sigma_t &= (I - K_t C_t) \overline{\Sigma}_t. \end{aligned}$$

Anschaulich gewichtet die Kalman-Verstärkung den Einfluss der Innovation auf die Zustandsschätzung, indem die Unsicherheit in der Vorhersage zur Observationsunsicherheit in Verhältnis gesetzt wird. Ist beispielsweise die Unsicherheit in der Observation gering ($Q_t \approx 0$), wird die Vorhersage durch $C_t^{-1} \Delta z_t$ nahezu vollständig zu $\mu_t = C_t^{-1} z_t$ korrigiert, und die Kovarianz Σ_t wird durch $(I - K_t C_t) \approx 0$ stark reduziert. Andererseits ist die Kalman-Verstärkung gering, falls die Unsicherheit in der Vorhersage klein

im Vergleich zur Observation ist, sodass die Zustandsschätzung kaum in Richtung der Observation korrigiert wird.

Das Kalmanfilter ist für niederdimensionale Zustände und Observationen eine äußerst effiziente Filtermethode. Die Vorhersage kann für $n := \dim(x_t)$ in $O(n^2)$ Operationen berechnet werden. Zur Bestimmung der Kalman-Verstärkung muss eine Matrix der Dimension $\mathbb{R}^{m\times m}, m := \dim(z_t)$, invertiert werden, was mit aktuellen Invertierungsverfahren in $O(m^{2.4})$ Operationen bewerkstelligt werden kann.

Das bisherige Verfahren setzt lineare Zustandsübergangs- und Observationsmodelle voraus. Typische Bewegungs- und Observationsmodelle in der Robotik sind jedoch nichtlinear, beispielsweise aufgrund von Orientierungen. Um die Vorzüge des Kalmanfilters in Einfachheit und Effizienz dennoch nutzen zu können, müssen die nichtlinearen Zustandübergangs- und Observationsmodelle

$$\begin{aligned} x_t &= g(x_{t-1}, u_t) + \epsilon_t, \text{und} \\ z_t &= h(x_t) + \delta_t \end{aligned}$$

linear approximiert werden. Für das erweiterte Kalmanfilter (EKF) [3] werden die nichtlinearen Modelle durch Taylorentwicklung erster Ordnung um den Mittelwert der aktuellen Zustandsschätzung linearisiert:

$$\begin{aligned} g(x_{t-1}, u_t) &\approx g(\mu_{t-1}, u_t) + \underbrace{\nabla_{x_{t-1}} g(x_{t-1}, u_t)\big|_{\mu_{t-1}}}_{=:\, G_t}(x_{t-1} - \mu_{t-1}), \\ h(x_t) &\approx h(\mu_t) + \underbrace{\nabla_{x_t} h(x_t)\big|_{\mu_t}}_{=:\, H_t}(x_t - \mu_t) \end{aligned}$$

Bei gegebener Zustandsschätzung (μ, Σ) ist diese Approximation nur dann zulässig, falls die Funktionen g und h in der näheren Umgebung von μ näherungsweise linear ist. Üblicherweise wird die Linearität innerhalb der Umgebung $U := \{x \in \mathbb{R}^n | x = \mu + Ay, y \in \mathbb{R}^n, \|y\|_2 = 2\}$ mit der Cholesky-Zerlegung $\Sigma = A^T A$ gefordert. Gerade bei hoher Unsicherheit kann diese Bedingung leicht verletzt sein, sodass der Fehler in der Schätzung steigt, während die Unsicherheit reduziert wird, was zur Divergenz des Verfahrens führt.

Mit diesen Approximationen erhält man das erweiterte Kalmanfilterverfahren mit Vorhersage

$$\begin{aligned} \overline{\mu}_t &= g(\mu_{t-1}, u_t) \\ \overline{\Sigma}_t &= G_t \Sigma_{t-1} G_t^T + R_t \end{aligned}$$

und Korrektur

$$\begin{aligned} \Delta z_t &= z_t - h(\overline{\mu}_t) \\ K_t &= \overline{\Sigma}_t H_t^T (H_t \overline{\Sigma}_t H_t^T + Q_t)^{-1} \\ \mu_t &= \overline{\mu}_t + K_t \Delta z_t \\ \Sigma_t &= (I - K_t H_t)\overline{\Sigma}_t. \end{aligned} \tag{3.2}$$

3.3.2 Das Partikelfilter

Parametrische Verfahren erfordern starke Annahmen über die Form der zu schätzenden Wahrscheinlichkeitsverteilung. Für die Darstellung und Schätzung beliebiger, insbesondere multimodaler Wahrscheinlichkeitsverteilungen, stehen approximative Verfahren zur

Verfügung, die den Zustandsraum in unterschiedlicher Weise diskretisieren. Zudem ist es für nichtparametrische Verfahren nicht erforderlich, Zustandsübergangs- und Observationsmodelle zu linearisieren. Stattdessen ist die Güte der Approximation hauptsächlich von der Gestalt der Diskretisierung abhängig.

Während in Histogrammfiltern der Zustandsraum in eine endliche Anzahl von Intervallen fester Größe und Positionen unterteilt wird, stellt man die Zustandsschätzung in Partikelfiltern als endliche Menge von M gewichteten Stichproben $X_t := \{x_t^{[i]}, i \in \{1, \ldots, M\}\}$ mit Gewichten $W_t := \{w_t^{[i]}, i \in \{1, \ldots, M\}\}$ dar. Die Stichproben $x_t^{[i]}$ werden als Partikel bezeichnet und können anschaulich als Hypothesen für den aktuellen Zustand zum Zeitpunkt t betrachtet werden. Die Gewichte der Partikel entsprechen der Wahrscheinlichkeit eines Partikels, zu einer uniform gewichtete Stichprobenmenge mit Zurücklegen in eine neue Partikelmenge gezogen zu werden. Sind die Partikel uniform gewichtet, das heißt $\forall i \in \{1, \ldots, M\} : w_t^{[i]} = 1$, entspricht die relative Häufigkeit von Partikeln in einem gegebenen Bereich des Zustandsraums der Wahrscheinlichkeit, dass sich der aktuelle Zustand innerhalb dieses Bereichs befindet. Daher entspricht für $M \to \infty$ die Verteilung der Partikel exakt der zu schätzenden Wahrscheinlichkeitsverteilung.

Im rekursiven Partikelfilterverfahren wird nun die Zustandsschätzung $bel(x_t)$ als Menge $\mathcal{X}_t = \{(x_t^{[i]}, w_t^{[i]})\}$ von gewichteten Partikel dargestellt. Die initiale Schätzung $p(x_0)$ kann damit beliebig initialisiert werden. Ziel des Verfahrens ist es, aus der Menge $\mathcal{X}_{t-1}$ und den Daten u_t und z_t eine Stichprobenmenge $\mathcal{X}_t$ zu erzeugen, die der Zielverteilung $bel(x_t)$ folgt. Dies wird mit dem sogenannten Sampling-Importance-Resampling-Verfahren (SIR) in folgender Weise bewerkstelligt:

a. Sampling: Zunächst wird für jede Stichproben $x_{t-1}^{[i]}$ gemäß des probabilistischen Zustandsübergangsmodells $p(x_t|u_t, x_{t-1})$ und der Kontrolleingabe u_t eine neue Stichprobe $x_t^{[i]}$ gezogen. Die erhaltene Partikelmenge $\overline{\mathcal{X}}_t$ approximiert die Vorschlagsverteilung $p(x_t|u_t, x_{t-1})bel(x_{t-1})$.

b. Importance: Die Stichproben $x_t^{[i]}$ werden mit der Wahrscheinlichkeit der Observation z_t im Zustand $x_t^{[i]}$ gewichtet, sodass $w_t^{[i]} = p(z_t|x_t^{[i]})$. Das Partikel wird auf diese Weise mit dem Fehler zwischen Ziel- und Vorschlagsverteilung gewichtet, d.h. $w_t^{[i]} = \frac{\text{Zielverteilung}}{\text{Vorschlagsverteilung}}$.

c. Resampling: Aus der gewichteten Partikelmenge $\overline{\mathcal{X}}_t$ wird die uniform gewichtete Partikelmenge $\mathcal{X}_t$ durch Ziehen von Stichproben mit Zurücklegen erzeugt. Das Gewicht eines Partikels gibt die Wahrscheinlichkeit an, mit der ein Partikel aus $\overline{\mathcal{X}}_t$ in $\mathcal{X}_t$ enthalten ist. Somit approximiert die Partikelmenge $\mathcal{X}_t$ die Zielverteilung $bel(x_t)$.

Das Verfahren liefert nur eine Approximation der Zielverteilung. Zieht man eine endliche Menge an Stichproben von einer Wahrscheinlichkeitsverteilung, stimmt die Verteilung der Stichproben nur näherungsweise mit der Ziehungsverteilung überein. Diese Variabilität wird als Varianz des Stichprobenverfahrens bezeichnet. Zudem besteht insbesondere durch das Resampling das Problem der Partikelverarmung: Durch eine ungünstige Abfolge von Zufallszügen kann ein erheblicher Anteil der Stichproben demselben Partikel entstammen, sodass die Diversität in der Partikelmenge stark reduziert wird. Unter Umständen werden so Hypothesen in gewissen Bereichen des Zustandsraums ausgelöscht, die in späteren Zeitschritten relevant wären.

Es bestehen diverse Möglichkeiten diesen Schwierigkeiten zu begegnen:

a. Partikelzahl erhöhen: Die Varianz des Stichprobenfahrens sinkt mit steigender Zahl von Partikeln. Allerdings bedeutet dies einen erhöhten Aufwand in Laufzeit und Speicher, sodass ein geeigneter Kompromiss für die Partikelzahl gefunden werden muss.

b. Resampling auslassen: Eine weitere Möglichkeit, die Varianz zu vermindern, besteht in der Auslassung des Resampling-Schritts. Dazu werden die Gewichte der Partikel nach dem Sampling-Schritt wie folgt aktualisiert:

$$w_t^{[i]} = \begin{cases} 1 & \text{, nach Resampling} \\ p(z_t|x_t^{[i]})w_{t-1}^{[i]} & \text{, sonst} \end{cases}$$

Der richtige Zeitpunkt, das Resampling durchzuführen, muss sorgfältig gewählt werden, denn zu häufiges Resampling führt zur Verarmung der Partikelmenge. Findet das Resampling hingegen zu selten statt, kann die Zahl der Partikel mit geringem Gewicht steigen, sodass Partikel in unwahrscheinlichen Bereichen des Zustandsraums verschwendet werden. Ein Indikator für die Varianz in den Partikelgewichten ist die Zahl der effektiven Partikel [26, 27]

$$M_{eff} = \frac{1}{\sum_i (\widetilde{w}_t^{[i]})^2}, \widetilde{w}_t^{[i]} := \frac{w_t^{[i]}}{\sum_j w_t^{[j]}}$$

Sind die Gewichte uniform, gilt $M_{eff} = M$. Je höher die Varianz in den Gewichten, desto mehr Wahrscheinlichkeitsmasse fällt auf wenige Partikel und umso geringer ist M_{eff}. Sinkt die Zahl der effektiven Partikel unter einen festgelegten Schwellwert χ_{eff}, sollte ein Resampling-Schritt durchgeführt werden. Üblicherweise wählt man $\chi_{eff} = \frac{1}{2}M$ als Schwellwert.

c. Resampling-Strategie: Einen wichtigen Einfluß auf die Varianz besitzt die Strategie, mit der während des Resampling-Schrittes neue Stichproben gemäß der Partikelgewichte gezogen werden. Anstatt Partikel stochastisch unabhängig mit dem normalisierten Gewicht als Wahrscheinlichkeit zu ziehen, erfolgt die Ziehung im Low-Variance-Sampling-Verfahren sequentiell. Zunächst wird das Intervall $[0; 1]$ in M Teilintervalle $I^{[i]}, i \in \{1, \ldots, M\}$ aufgeteilt, deren Länge durch die Gewichte $w^{[i]}$ gegeben ist. Anschließend wird eine Zufallszahl r uniform aus dem Intervall $\left[0; \frac{1}{M}\right]$ bestimmt. Es werden nun M Stichproben gezogen, indem für $u_k := r + \frac{k-1}{M}, k \in \{1, \ldots, M\}$ diejenigen Teilintervalle $I_k := I^{[i]}$ bestimmt werden, die die Werte u_k enthalten. Für jedes dieser Teilintervalle wird das zugehörige Partikel in die Stichprobe aufgenommen.

3.3.3 Rekursives Filter für statische, binäre Zustände

Für statische Zustände x mit zwei möglichen Werten x und $\neg x$ existiert eine spezielle rekursive Filtermethode, die beispielsweise zur Schätzung der Belegtheit von Zellen in Gitterkarten Verwendung findet.

Ziel des Verfahrens ist es, die Wahrscheinlichkeit von x anhand der Observationen $z_{1:t}$ des Zustands zu schätzen:

$$bel_t(x) := p(x|z_{1:t})$$

Offensichlich lässt sich die Schätzung für $\neg x$ leicht aus $bel_t(\neg x) = 1 - bel_t(x)$ berechnen.

Eine Variante zur rekursiven Zustandsschätzung besteht in der direkten Verwendung des rekursiven Bayesschen Filters für diskrete Zustände (Gl. 3.1). Allerdings ist eine kompaktere Darstellung der Schätzung möglich, die das logarithmische Verhältnis zwischen x und $\neg x$ schätzt und statt des kausalen Observationsmodells die diagnostische, inverse Form verwendet:

$$\begin{aligned} l_t &:= log \frac{p(x|z_{1:t})}{1 - p(x|z_{1:t})} \\ &= l_{t-1} + log \frac{p(x|z_t)}{1 - p(x|z_t)} - log \frac{p(x)}{1 - p(x)} \end{aligned}$$

Der Vorteil dieser Darstellung liegt in der numerischen Stabilität für Werte von $bel_t(x)$ nahe 0 und 1. Die Zustandsschätzung $bel_t(x)$ ergibt sich aus dem logarithmischen Verhältnis l_t:

$$bel_t(x) = 1 - \frac{1}{1 + e^{l_t}}.$$

3.4 Lokalisation

Damit ein Roboter erfolgreich in seiner Umgebung navigieren kann, muss er durch Observationen der Umgebung und Kenntnis über seine Fortbewegung eine robuste Schätzung seiner Pose erlangen. Zunächst betrachten wir das Problem der Lokalisation des Roboters unter der Voraussetzung, dass eine landmarkenbasierte Repräsentation der Karte $m = \{L_j\}_{j=1}^N$ aus N eindeutig identifizierbaren Landmarken zur Verfügung steht. Die Lokalisation kann in drei Kategorien zunehmender Schwierigkeit unterteilt werden:

a. Posenverfolgung Bei der Posenverfolgung steht bereits zu Beginn des Lokalisationsprozesses eine ausreichend genaue Zustandsschätzung zur Verfügung. Die Unsicherheit in der Posenschätzung bleibt auf einen lokalen Bereich um die tatsächliche Pose beschränkt. Die Verwendung eines unimodalen, parametrischen Schätzverfahrens ist in vielen Fällen ausreichend.

b. Globale Lokalisation Die globale Lokalisation bezeichnet die Posenschätzung, falls die initiale Pose des Roboters nicht bekannt ist. Gerade zu Beginn der Zustandsschätzung kann es notwendig sein, diverse Hypothesen über die Pose des Roboters zu erhalten. Unimodale, parametrische Verfahren sind daher in naiver Form für dieses Problem ungeeignet.

c. Entführungsproblem Ein erhöhter Schwierigkeitsgrad bei der globalen Lokalisation ist gegeben, falls sich die Pose während der Schätzung sprunghaft ändern kann. Anschaulich könnte der Roboter von seiner aktuellen Pose an eine andere Stelle gebracht werden. Ist ein Lokalisationsverfahren in der Lage, trotz einer solchen sprunghaften Posenänderung erneut eine korrekt Schätzung der Pose zu erlangen, ist es insbesondere robust gegenüber Lokalisierungsfehlern.

Für die Schätzung der Pose des Roboters s_t aus Landmarkenobservationen $z_{1:t}$ und Kontrolleingaben $u_{1:t}$

$$bel(s_t) = p(s_t|z_{1:t}, u_{1:t})$$

können je nach Kategorie des vorliegenden Lokalisierungsproblems bestimmte rekursive Bayessche Filtermethoden angewandt werden. Für die Posenverfolgung eignen sich insbesondere parametrische Verfahren wie das erweiterte Kalmanfilter. Da das Partikelfilter

beliebige Wahrscheinlichkeitsverteilungen approximiert, kann es auch für globale Lokalisationsprobleme verwendet werden. Dieses Lokalisationsverfahren wird als Monte-Carlo-Lokalisation (MCL) bezeichnet.

Algorithmus 1 : Monte-Carlo-Lokalisation

Eingabe : $\mathcal{S}_{t-1}, z_t, u_t, m$
Ausgabe : $\mathcal{S}_t$

1 $\overline{\mathcal{S}}_t \leftarrow \emptyset$
2 **forall** $i \in \{1, \ldots, M\}$ **do**
3 $\quad \overline{s}_t^{[i]} \sim p(s_t | u_t, s_{t-1}^{[i]})$
4 $\quad \overline{w}_t^{[i]} \leftarrow p(z_t | \overline{s}_t^{[i]}, m)$
5 $\quad \overline{\mathcal{S}}_t \leftarrow \overline{\mathcal{S}}_t \cup \{(\overline{s}_t^{[i]}, \overline{w}_t^{[i]}\ )\ \}$
6 **end**
7 $\mathcal{S}_t \leftarrow$ resample($\overline{\mathcal{S}}_t$)

Der MCL-Algorithmus (Abb. 1) ist eine direkte Umsetzung des SIR-Partikelfilterverfahrens. Er generiert aus der Partikelmenge $\mathcal{S}_{t-1}$, der Observation z_t, der Kontrolleingabe u_t und der landmarkenbasierten Karte m eine neue Partikelmenge $\mathcal{S}_t$, die $bel(s_t)$ approximiert. Die Funktion resample in Zeile 7 kann beispielsweise durch Low-Variance-Resampling implementiert werden.

3.5 Kartieren von Landmarken

Zur Lokalisation wurde bisher vorausgesetzt, dass eine Karte der Umgebung zur Verfügung steht, in der Observationen eindeutig Landmarken zugeordnet werden können. Das komplementäre Problem der Schätzung einer Karte von Landmarken kann unter der Voraussetzung, dass die Pose des Roboters zu jedem Zeitpunkt bekannt ist, ebenfalls durch rekursive Bayessche Filterverfahren gelöst werden.

Das Schätzen einer landmarkenbasierten Karte $m := \{L_j\}_{j=1}^N$ aus eindeutig zu Landmarken zugeordneten Observationen $z_{1:t}$ in bekannten Posen $s_{1:t}$ kann als Schätzung der Wahrscheinlichkeitsverteilung

$$bel_t(m) = p(m | z_{1:t}, c_{1:t}, s_{1:t})$$

formuliert werden. Die Korrespondenzvariable $c_t = j$ gibt die Zugehörigkeit der Observation z_t zur Landmarke L_j an. Der Zeitindex t bedeutet hier, dass die Schätzung der Karte auf Observationen und Posen bis zum Zeitpunkt t beruht. Die Positionen l_j von Landmarken sind weiterhin statisch. Die stochastischen Abhängigkeiten des Kartierungsproblems sind in Abb. 3.2 illustriert.

Aus Abb. 3.2 ist ersichtlich, dass bei gegebener Trajektorie $s_{1:t}$, gegebenen Observationen $z_{1:t}$ und gegebenen Korrespondenzen $c_{1:t}$ die einzelnen Landmarkenpositionsschätzungen d-separiert [28] und somit stochastisch unabhängig sind, d.h.

$$p(l_1, \ldots, l_N | z_{1:t}, c_{1:t}, s_{1:t}) = \prod_{j=1}^{N} p(l_j | z_{1:t}, c_{1:t}, s_{1:t}).$$

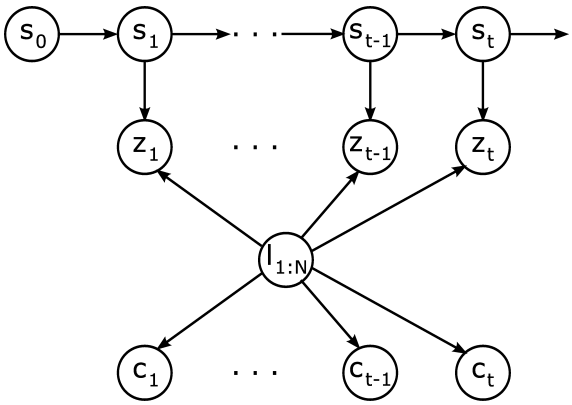

Abbildung 3.2: Darstellung der stochastischen Abhängigkeiten des Kartierungsproblems als dynamisches Bayessches Netzwerk. Zu jedem Zeitpunkt t wird in der Pose s_t eine Landmarke in der Position l_j durch z_t observiert. Die Korrespondenzvariable $c_t = j$ gibt die Korrespondenz von Observation z_t zur Landmarke L_j an.

Die Art des verwendbaren rekursiven Bayesschen Filters hängt nun grundlegend vom Vorwissen über die Landmarkenposition und die Gestalt des Observationsmodells ab. Werden Distanz und Winkel zur Landmarke mit ausreichender Genauigkeit gemessen, ist die zweidimensionale Position der Landmarke direkt observierbar, sodass die Positionsschätzung bereits bei der ersten Observation der Landmarke durch Invertieren des Observationsmodells initialsiert werden kann. Kann das Observationsmodell normalverteilt dargestellt werden, d.h. $z_t = h(l_{c_t,t}, s_t) + \delta_t, \delta_t \sim \mathcal{N}(0; Q_t)$, bieten sich zur Schätzung insbesondere erweitere Kalmanfilter mit Positionsschätzungen $\mathcal{L}_t := \{(\mu_{j,t}, \Sigma_{j,t})\}_{j=1}^{N}$ für jede Landmarkenposition an.

Der EKF-Kartierungsalgorithmus (Alg. 2) initialisiert in Zeile 5 Mittelwert und Kovarianz von Landmarken, falls sie noch nicht observiert wurden. Die Anwendung des inversen Observationsmodells $h^{-1}(z, s)$ liefert die mittlere Landmarkenposition in der Pose s_t bei der Observation z_t. Die Kovarianz wird durch Linearisierung des inversen Observationsmodells um die Pose s_t und die Observation z_t bestimmt,

$$\Sigma_{i,t} = H_{inv} Q_t H_{inv}^T \ , \ \text{wobei } H_{inv} := \nabla_z h^{-1}(z, s)\big|_{z_t, s_t} .$$

Ist die Landmarke bereits initialisiert, wird in Zeile 7 die Landmarkenpositionsschätzung durch einen Korrekturschritt des EKF (Gl. (3.2)) aktualisiert.

Algorithmus 2 : EKF-Kartieren

Eingabe : $\mathcal{L}_{t-1}, z_t, c_t, s_t$
Ausgabe : $\mathcal{L}_t$

```
1  L_t ← ∅
2  forall i ∈ {1, ..., N} do
3      if c_t == i then
4          if l_{i,t} uninitialisiert then
5              (μ_{i,t}, Σ_{i,t}) ← (h^{-1}(z_t, s_t), H_inv Q_t H_inv^T)
6          else
7              (μ_{i,t}, Σ_{i,t}) ←EKF-Korrektur((μ_{i,t-1}, Σ_{i,t-1}), z_t, s_t)
8          end
9      else
10         (μ_{i,t}, Σ_{i,t}) ← (μ_{i,t-1}, Σ_{i,t-1})
11     end
12     L_t ← L_t ∪ (μ_{i,t}, Σ_{i,t})
13 end
```

3.6 Simultanes Lokalisieren und Kartieren

Bisher wurde für Lokalisation und Kartieren von Landmarken vorausgesetzt, dass die Karte der Umgebung bzw. die Pose des Roboters bekannt ist. In Anwendungsszenarien ist es allerdings nicht möglich oder gewollt, Vorwissen über Pose oder Karte des Roboters bereitzustellen. Vielmehr soll ein Roboter bei der Exploration einer unbekannten Umgebung in der Lage sein, zu einer robusten Schätzung einer Umgebungsrepräsentation und seiner Pose darin zu gelangen. Offensichtlich sind hierfür wechelseitig konsistente Schätzungen erforderlich: Zur erfolgreichen Lokalisation muss eine korrekte Karte zur Verfügung stehen, für die iterative Schätzung der Karte muss die Posenschätzung innerhalb der Karte korrekt sein.

Das simultane Lokalisieren und Kartieren kann wiederum als stochastischer Prozess formuliert werden, dessen stochastische Abhängigkeiten in Abb. 3.3 dargestellt sind. Das SLAM-Problem bei bekannten Korrespondenzen von Observationen zu Landmarken besteht in der Schätzung der Trajektorie $s_{0:t}$ und Karte m aus Observationen und Kontrolleingaben,

$$p(s_{0:t}, m | z_{1:t}, c_{1:t}, u_{1:t}).$$

Soll nur die aktuelle Pose s_t geschätzt werden, muss über die vergangenen Posen marginalisiert werden:

$$p(s_t, m | z_{1:t}, c_{1:t}, u_{1:t}) = \int \dots \int p(s_{0:t}, m | z_{1:t}, c_{1:t}, u_{1:t}) ds_{t-1} \dots ds_0$$

Diese Schätzung wird als online bezeichnet, da sie die vollständige Trajektorie nicht explizit speichert, was einen Speicherverbrauch polynomiell in den vergangenen Zeitschritten erfordern würde.

Es wurden diverse Online-SLAM-Verfahren entwickelt. In EKF-SLAM-Verfahren wird der zu schätzende Zustand $x_t := (s_t, l_1, \dots, l_N)^T$ als Verbund aus aktueller Pose s_t und

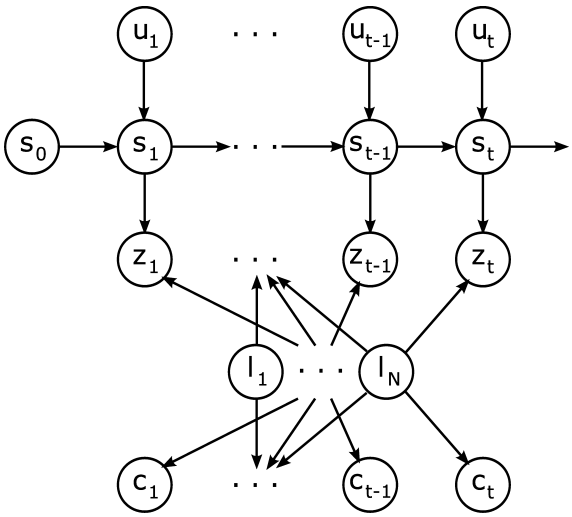

Abbildung 3.3: Darstellung der stochastischen Abhängigkeiten in SLAM als dynamisches Bayessches Netzwerk. Zu jedem Zeitpunkt t wird in der Pose s_t eine Landmarke in der Position l_j durch z_t observiert. Die Korrespondenzvariable $c_t = j$ gibt die Korrespondenz von Observation z_t zu Landmarke l_j an. Die Pose s_t geht aus der vergangenen Pose s_{t-1} unter dem Einfluss der Kontrolleingabe u_t hervor.

Landmarkenpositionen $l_1, \ldots, l_N$ dargestellt. Ein erweiteres Kalmanfilter schätzt Mittelwert und Kovarianz dieses Zustands. Da die Laufzeit des EKF quadratisch in der Dimension des Zustandsvektors ist, und auch eine entsprechend grosse Zustandskovarianzmatrix gespeichert werden muss, können nur wenige hundert Landmarken kartiert werden.

3.6.1 Landmarkenbasiertes FastSLAM

Partikelfilter können nicht direkt zur Schätzung des kombinierten Zustands aus aktueller Pose und Karte herangezogen werden, denn die benötigte Zahl der Partikel, um einen Zustand mit ausreichender Güte zu approximieren, steigt exponentiell mit der Dimensionalität des Zustands. Das SLAM-Problem besitzt allerdings eine besondere Struktur: Ist die vollständige Trajektorie des Roboters bekannt, sind die Landmarkenpositionsschätzungen im Abhängigkeitsgraphen d-separiert (s. Abb. 3.3), sodass sie unabhängig voneinander geschätzt werden können:

$$\begin{aligned} p(s_{0:t}, m | z_{1:t}, c_{1:t}, u_{1:t}) &= p(s_{0:t} | z_{1:t}, c_{1:t}, u_{1:t}) \cdot p(m | s_{0:t}, z_{1:t}, c_{1:t}, u_{1:t}) \\ &= p(s_{0:t} | z_{1:t}, c_{1:t}, u_{1:t}) \prod_{j}^{N} p(l_j | s_{0:t}, z_{1:t}, c_{1:t}, u_{1:t}) \end{aligned}$$

Das FastSLAM-Verfahren [10] nutzt diese Eigenschaft aus, um Trajektorie und einzelne Landmarken mit einem Rao-Blackwellisierten Partikelfilter zu schätzen. Rao-Blackwellisierte Partikelfilter zerlegen eine mehrdimensionale Wahrscheinlichkeitsverteilung, indem ein Partikel lediglich eine Teilmenge der Zustandsvariablen als diskrete Hypothese enthält. Die übrigen Zustandsvariablen werden in jedem Partikel individuell geschätzt. In FastSLAM besteht ein Partikel $x_t^{[i]} \in \mathcal{X}_t$ aus der Posenhypothese $s_t^{[i]}$

und normalverteilt parametrisierten Schätzungen $\mathcal{L}_t^{[i]} := (\mu_{j,t}^{[i]}, \Sigma_{j,t}^{[i]})_{j=1}^N$ der Landmarken:

$$x_t^{[i]} = \left\langle s_t^{[i]}, (\mu_{1,t}^{[i]}, \Sigma_{1,t}^{[i]}), \ldots, (\mu_{N,t}^{[i]}, \Sigma_{N,t}^{[i]}) \right\rangle .$$

Die vollständige Trajektorie eines Partikels ist in der Historie der gezogenen Posenstichproben $s_{0:t}^{[i]}$ enthalten. Somit ist FastSLAM ein Online-SLAM-Verfahren, das auch das vollständige SLAM-Problem löst.

Die ursprüngliche Variante des FastSLAM-Verfahrens kann anschaulich als Kombination aus Monte-Carlo-Lokalisation und EKF-Kartieren aufgefasst werden. Die rekursive Schätzung von Trajektorie und Karte wird in folgenden Schritten durchgeführt:

a. Sampling: Zunächst wird für jedes Partikel $i \in \{1, \ldots, M\}$ eine neue Pose $s_t^{[i]}$ gemäss des probabilistischen Zustandsübergangsmodells anhand der Kontrolleingabe u_t und der Partikelpose $s_{t-1}^{[i]}$ gezogen:

$$s_t^{[i]} \sim p(s_t | s_{t-1}^{[i]}, u_t)$$

Die Partikel in der resultierenden Partikelmenge $\overline{\mathcal{X}}_t$ folgen der Vorschlagsverteilung $p(s_t^{[i]} | s_{t-1}^{[i]}, u_t)\ p(s_{1:t-1}^{[i]} | z_{1:t-1}, u_{1:t-1}, c_{1:t-1}) = p(s_t^{[i]} | z_{1:t-1}, u_{1:t}, c_{1:t-1})$.

b. Kartenaktualisierung: Die Landmarkenschätzungen werden rekursiv anhand der Partikelpose $s_t^{[i]}$, der Observation z_t und der Landmarkenkorrespondenz c_t durch EKF-Kartieren aktualisiert:

$$\mathcal{L}_t^{[i]} = \text{EKF-Kartieren}(\mathcal{L}_{t-1}^{[i]}, z_t, c_t, s_t^{[i]})$$

c. Importance: Die Zielverteilung der Partikel ist $p(s_t^{[i]} | z_{1:t}, u_{1:t}, c_{1:t})$. Die Partikel müssen mit dem Verhältnis von Ziel- zu Vorschlagsverteilung gewichtet werden:

$$\begin{aligned} w_t^{[i]} &= \frac{\text{Zielverteilung}}{\text{Vorschlagsverteilung}} \\ &= \frac{p(s_t^{[i]} | z_{1:t}, u_{1:t}, c_{1:t})}{p(s_t^{[i]} | z_{1:t-1}, u_{1:t}, c_{1:t-1})} \\ &= \ldots \\ &= \eta \int p(z_t | l_{c_t}, s_t^{[i]}, z_{1:t-1}, c_{1:t})\ p(l_{c_t} | s_t^{[i]}, z_{1:t-1}, c_{1:t})\ dl_{c_t} \end{aligned}$$

Das Integral entspricht der Observationswahrscheinlichkeit von z_t in der Pose $s_t^{[i]}$ unter der normalverteilten Landmarkenpositionsschätzung $(\mu_{c_t,t-1}^{[i]}, \Sigma_{c_t,t-1}^{[i]})$ für l_{c_t} aus dem Zeitschritt $t-1$. Sie kann durch Taylorentwicklung erster Ordnung des Observationsmodells um $s_t^{[i]}$ und $\mu_{c_t,t-1}^{[i]}$ approximiert werden:

$$w_t^{[i]} \approx \eta \det(2\pi Z_t)^{-\frac{1}{2}} e^{-\frac{1}{2}\Delta z_t^T Z_t^{-1} \Delta z_t}$$

mit Innovation $\Delta z_t := z_t - h(\mu_{c_t,t-1}^{[i]}, s_t^{[i]})$ und Observationskovarianz $Z_t := H_t \Sigma_{c_t,t-1}^{[i]} H_t^T + Q_t$, $H_t := \nabla_\mu h(\mu, s)|_{\mu_{c_t,t-1}^{[i]}, s_t^{[i]}}$.

Die Normalisierungskonstante η hängt nicht von Trajektorie und Karte des Partikels ab und ist somit für alle Partikel identisch. Sie kann durch Normalisieren der Gewichte während des Resamplings berücksichtigt werden.

d. Resampling Es wird eine neue Partikelmenge $\mathcal{X}_t$ durch Ziehen von Stichproben mit Zurücklegen aus $\overline{\mathcal{X}}_t$ erzeugt. Die normalisierten Gewichte der Partikel entsprechen der Wahrscheinlichkeit eines Partikels, in die neue Partikelmenge gezogen zu werden.

Sei M die Anzahl der Partikel und N die Anzahl der Landmarken. Eine naive Implementation des Verfahrens benötigt im ungünstigsten Fall $O(MN)$ Laufzeit, da jedes Partikel im Sampling-Schritt gemäss des Zustandübergangmodells propagiert und im Resampling-Schritt aus den M Partikeln eine neue Partikelmenge gezogen wird. Wird ein Partikel während des Resamplings mehrfach gezogen, muss die gesamte Karte aus N Landmarken kopiert werden, sodass die Karte im ungünstigsten Fall M mal kopiert wird. Montemerlo et al. [10] schlagen eine effiziente Baumstruktur vor, in der Landmarkenschätzungen während des Resamplings nicht kopiert werden, sondern zunächst ein Zeiger auf die Schätzung im generierenden Partikel gespeichert wird. Erst bei der nachfolgenden Observation einer verknüpften Landmarke werden lokale Kopien einer Landmarke erzeugt. Durch die Verwendung dieser Baumstruktur kann die Laufzeit des FastSLAM-Verfahrens amortisiert zu $O(M \log(N))$ reduziert werden.

3.6.2 FastSLAM 2.0

Im vorgestellten FastSLAM-Verfahren werden Partikel im Sampling-Schritt gemäss des Bewegungsmodells propagiert. Falls das Bewegungsmodell relativ zum Observationsmodell deutlich unsicherer ist, sind viele Partikel notwendig, um Stichproben im relevanten Posenbereich zu erzeugen, in dem Observationen eine hohe Wahrscheinlichkeit besitzen. Zudem ist es wahrscheinlicher, dass eine Folge von ungünstigen Posenstichproben zur Auslöschung von Partikeln führen, die eigentlich eine konsistente Trajektorien- und Kartenhypothese tragen. Eine künstliche Vergrößerung der Unsicherheit im Observationsmodell kann diese Probleme zwar beseitigen, allerdings auf Kosten von Informationsgehalt einer Messung.

Ein vorteilhafterer Ansatz besteht in der Verwendung einer Vorschlagsverteilung, die die Zielverteilung besser approximiert, und somit mehr Stichproben im relevanten Zustandsbereich generiert [5]. Statt direkt das Zustandübergangmodell zum Ziehen von Stichproben zu verwenden, wird die Posenschätzung anhand des Zustandsübergangsmodells zunächst durch die aktuellen Observationen korrigiert. Im Sampling-Schritt werden anschließend Posen von dieser korrigierten Posenverteilung gezogen. Die Karte wird wie zuvor anhand der gezogenen Pose des Partikels und der aktuellen Observation aktualisiert. Die Verwendung dieser neuen Vorschlagsverteilung muss schliesslich bei der Gewichtung der Partikel berücksichtigt werden.

Die verbesserte Sampling-Verteilung

$$p(s_t | s_{1:t-1}^{[i]}, u_{1:t}, z_{1:t}, c_{1:t}) \tag{3.3}$$

berücksichtigt im Vergleich zur ursprünglichen Verteilung zusätzlich die aktuelle Observation z_t und Landmarkenkorrespondenz c_t. Durch Umformung [25] erhält man

$$p(s_t | s_{1:t-1}^{[i]}, u_{1:t}, z_{1:t}, c_{1:t}) = \eta^{[i]} \int p(z_t | l_{c_t}, s_t, c_t)\; p(l_{c_t} | s_{1:t-1}^{[i]}, z_{1:t-1}, c_{1:t-1})\; dl_{c_t} \cdot p(s_t | s_{t-1}^{[i]}, u_t)$$

mit $\eta^{[i]} = \left(p(z_t | s_{1:t-1}^{[i]}, u_{1:t}, z_{1:t-1}, c_{1:t}) \right)^{-1}$.

Um von dieser Verteilung Stichproben ziehen zu können, werden nichtlineare Zustandsübergangs- und Observationsmodelle mit normalverteiltem, additivem Rauschen vorausgesetzt:

$$x_t = g(x_{t-1}, u_t) + \epsilon_t, \epsilon_t \sim \mathcal{N}(0; R_t), \text{und}$$
$$z_t = h(l_{c_t}, x_t) + \delta_t, \delta_t \sim \mathcal{N}(0; Q_t)$$

Mit normalverteilten Landmarkenpositionsschätzungen sind die drei beteiligten Wahrscheinlichkeitsverteilungen normalverteilt:

$$p(s_t|s_{1:t-1}^{[i]}, u_{1:t}, z_{1:t}, c_{1:t}) = \eta^{[i]} \int \underbrace{p(z_t|l_{c_t}, s_t, c_t)}_{\sim\mathcal{N}(z_t;h(l_{c_t},s_t),Q_t)} \underbrace{p(l_{c_t}|s_{1:t-1}^{[i]}, z_{1:t-1}, c_{1:t-1})}_{\sim\mathcal{N}(l_{c_t};\mu_{c_t,t-1}^{[i]},\Sigma_{c_t,t-1}^{[i]})} dl_{c_t} \cdot \underbrace{p(s_t|s_{t-1}^{[i]}, u_t)}_{\sim\mathcal{N}(s_t;g(s_{t-1}^{[i]},u_t),R_t)}$$

Wäre das Observationsmodell h linear, besäße diese Faltung zweier Normalverteilung und anschließende Multiplikation mit einer Normalverteilung eine analytische Lösung. Das Observationsmodell wird daher durch Taylorexpansion erster Ordnung um die erwartete Observation $\hat{z}_t^{[i]} := h(\mu_{c_t,t-1}^{[i]}, \hat{s}_t^{[i]})$ in der mittleren Pose des Zustandsübergangsmodells $\hat{s}_t^{[i]} := g(s_{t-1}^{[i]}, u_t)$ linearisiert:

$$h(l_{c_t}, s_t) \approx \hat{z}_t^{[i]} + \underbrace{\nabla_{l_{c_t}} h(l_{c_t}, s_t)\big|_{\mu_{c_t,t-1},\hat{s}_t^{[i]}}}_{H_l} (l_{c_t} - \mu_{c_t,t-1}) + \underbrace{\nabla_{s_t} h(l_{c_t}, s_t)\big|_{\mu_{c_t,t-1},\hat{s}_t^{[i]}}}_{H_s} (s_t - \hat{s}_t^{[i]})$$

Diese Approximation führt zur [25] normalverteilten Sampling-Verteilung

$$p(s_t|s_{1:t-1}^{[i]}, u_{1:t}, z_{1:t}, c_{1:t}) \approx \eta^{[i]} \mathcal{N}(s_t; \mu_{s_t}^{[i]}, \Sigma_{s_t}^{[i]})$$

mit

$$\Sigma_{s_t}^{[i]} := \left(H_s^T (O_t^{[i]})^{-1} H_s + R_t^{-1}\right)^{-1},$$
$$\mu_{s_t}^{[i]} := \Sigma_{s_t}^{[i]} H_s^T (O_t^{[i]})^{-1} (z_t - \hat{z}_t^{[i]}) + \hat{s}_t^{[i]}$$

und der Unsicherheit in der erwarteten Observation $O_t^{[i]} := Q_t + H_l \Sigma_{c_t,t-1}^{[i]} H_l^T$.
Unter Berücksichtigung der verbesserten Vorschlagsverteilung ergeben sich [25] die Partikelgewichte zu

$$\begin{aligned} w_t^{[i]} &= \eta\, p(z_t|s_{1:t-1}^{[i]}, z_{1:t-1}, u_{1:t}, c_{1:t}) \\ &= \eta \int \underbrace{p(s_t|s_{t-1}^{[i]}, u_t)}_{\sim\mathcal{N}(s_t;g(s_{t-1}^{[i]},u_t),R_t)} \int \underbrace{p(z_t|l_{c_t}, s_t, c_t)}_{\sim\mathcal{N}(z_t;h(l_{c_t},s_t),Q_t)} \underbrace{p(l_{c_t}|s_{1:t-1}^{[i]}, u_{1:t-1}, z_{1:t-1}, c_{1:t-1})}_{\sim\mathcal{N}(l_{c_t};\mu_{c_t,t-1}^{[i]},\Sigma_{c_t,t-1}^{[i]})} dl_{c_t}\, ds_t. \end{aligned} \tag{3.4}$$

Durch Linearisierung des Observationsmodells h um $\hat{z}_t^{[i]}$ und $\hat{x}_t^{[i]}$ kann eine normalverteilte Approximation dieser Wahrscheinlichkeitsverteilung in z_t bestimmt werden. Mittelwert und Kovarianz sind $\hat{z}_t^{[i]}$ bzw. $Z_t^{[i]} := H_s R_t H_s^T + H_l \Sigma_{c_t,t-1}^{[i]} H_l^T + Q_t$. Anschaulich entspricht das Gewicht der Wahrscheinlichkeit der Observation z_t unter der unsicheren Posenverteilung im Sampling-Schritt und der Landmarkenpositionsschätzung des letzten Zeitschritts. Die Normalisierungskonstante $\eta = (p(z_t|u_{1:t}, z_{1:t-1}, c_{1:t}))^{-1}$ ist wie bereits im ursprünglichen Verfahren für alle Partikel identisch und kann durch Normalisieren der Gewichte einbezogen werden.

3.7 Datenassoziation bei unbekannter Korrespondenz

Die eindeutige Identifizierbarkeit von Landmarken ist keine notwendige Voraussetzung für simultanes Lokalisieren und Kartieren. Es können auch weniger diskriminative Landmarken kartiert werden, indem die nun unsicheren Korrespondenzen $c_{1:t}$ zusätzlich zu Trajektorie und Karte geschätzt werden:

$$p(s_{0:t}, m, c_{1:t}|z_{1:t}, u_{1:t})$$

Das Schätzen dieser Verteilung wird als vollständiges SLAM-Problem bezeichnet.

Die Wahrscheinlichkeit einer Korrespondenz von Observation zu Landmarke hängt wesentlich von den Unsicherheiten in Trajektorie und Karte ab, sodass die Korrespondenz nicht mehr eindeutig hergestellt werden kann. Es ist praktisch nicht möglich, jede mögliche Korrespondenz von Observationen zu Landmarken explizit zu repräsentieren und zu schätzen. Stattdessen muss dieses Datenassoziationsproblem approximativ gelöst werden, indem nur eine Teilmenge der möglichen Assoziationshypothesen aufrechterhalten wird. In EKF-SLAM kann beispielsweise nur eine einzige Datenassoziationshypothese je Observation verfolgt werden. Eventuell fehlerhafte Datenassoziation können nicht korrigiert werden, wirken sich aber fatal aus: Die Schätzung einer Landmarke wird mit einer nicht zugehörigen Observation verfälscht, indem der Fehler im Mittelwert der Schätzung im Allgemeinen ansteigt, während die Unsicherheit inkonsistent durch die Integration der Observation verringert wird.

In FastSLAM-Verfahren können mehrere Korrespondenzhypothesen verfolgt werden, indem die Datenassoziation für jedes Partikel individuell hergestellt wird. FastSLAM ist also robuster als EKF-SLAM für Probleme, in denen die Datenassoziation nicht eindeutig bestimmt werden kann.

Sind keine weiteren Informationen zur Datenassoziation als aktuelle Pose, Observation und Karte gegeben, kann sie modellgetrieben auf folgende Arten hergestellt werden:

a. Individual Compatibility Data Association: Eine Observation wird derjenigen Landmarke zugeordnet, die die Observationswahrscheinlichkeit unter Landmarkenpositions- und Posenschätzung maximiert:

$$c_t = argmax_j \{p(z_t|l_j, s_t)\}$$

Um robust gegenüber Ausreißern zu sein, sollte die Datenassoziation nur akzeptiert werden, falls die Observationswahrscheinlichkeit über einem festgelegten Schwellwert liegt [29]. Diese Art der Datenassoziation ist auch als Gated Nearest Neighbor bekannt. Die Laufzeit des Verfahrens für die Herstellung einer Korrespondenz liegt in $O(N)$.

b. Likelihood-Sampling: In FastSLAM-Verfahren können mehrere Datenassoziationshypothesen verfolgt werden. Daher können für die Korrespondenz c_t Stichproben mit Wahrscheinlichkeit proportional zur Observationswahrscheinlichkeit gezogen werden:

$$c_t \sim p(z_t | l_j, s_t)$$

c. Joint Compatibility Data Association: Werden die Korrelationen zwischen Landmarkenpositions- und Posenschätzungen explizit modelliert, können diese für die Datenassoziation berücksichtigt werden [30]. In EKF-SLAM sind diese Korrelationen durch die Kovarianz der Posen- und Kartenschätzung gegeben, während sie in FastSLAM nur indirekt in der Partikelmenge enthalten sind, sodass diese Methode in dieser Arbeit nicht verwendet werden kann.

4 Simulationsumgebung

Zur Entwicklung und Evaluation des SLAM-Verfahrens wurde eine Simulation einer zweidimensionalen Umgebung erstellt. Die simulierte Umgebung soll die getroffenen Annahmen über die reale Umgebung repräsentieren und so das Problem auf das wesentliche reduzieren.

4.1 Zweidimensionales Umgebungsmodell

Die Umgebung besteht aus geradlinigen Wandsegmenten, deren globale Orientierungen $\psi \in \left\{0, \frac{\pi}{2}, \pi, -\frac{\pi}{2}\right\}$ Vielfache von $\frac{\pi}{2}$ betragen, sodass die Segmente orthogonal bzw. parallel sind. Die Wandsegmente können durch Bitmaps in beliebiger Skalierung texturiert werden. Beleuchtung wird durch ambientes Licht und punktförmige Beleuchtungsquellen mit konfigurierbarer Leuchtstärke $B \in [0, 1]$ simuliert. Die punktförmigen Beleuchtungsquellen entsprechen zweidimensionalen Lambertschen Strahlern, d.h. die Beleuchtungsintensität I an einer Stelle x eines Wandsegments mit Orientierung ψ hängt von der Leuchtstärke der Lichtquelle, der Distanz d zur Lichtquelle und dem Auftreffwinkel α des Lichtstrahls ab, indem die Intensität mit zunehmendem Winkel zwischen Lichtstrahl und Segmentnormalen abnimmt:

$$I := \min\left(1, \max\left(0, B\left|\frac{\cos((\psi + \pi) - \alpha)}{1 + \delta \cdot d}\right|\right)\right)$$

Die Wandsegmente besitzen matte Reflektanz, sodass der observierte Farbwert an einer Stelle eines Wandsegments durch das Lambertsche Gesetz gegeben ist. Abb. 4.1 stellt eine simulierte Umgebung exemplarisch dar.

4.2 Physikalisches Robotermodell

Die Bewegung des Roboters in dieser Umgebung wird physikalisch simuliert. Der Roboter verfügt über einen omnidirektionalen Antrieb, dessen egozentrische Zielgeschwindigkeiten $v_{Target} := (v_{Target,x}, v_{Target,y}, \omega_{Target})$ in Translation und Rotation gesteuert werden können. Die ausführbaren Geschwindigkeitskomponenten sind im Betrag begrenzt. Die tatsächliche Geschwindigkeit $v_{Actual} = v_{Target} + \epsilon_t$ des Roboters unterliegt normalverteiltem Rauschen $\epsilon_t \sim \mathcal{N}(0, S_t)$, um Unsicherheiten durch Störeinflüsse und Ungenauigkeiten in der Bewegungsmodellierung zu simulieren. Sei Δt das Zeitintervall zwischen aufeinanderfolgenden Simulationsschritten. Um die gesteuerte Zielgeschwindigkeit zu erreichen, wird der Roboter um den Fehler $\Delta v := v_{Target} - v_{Actual}$ mit $a_{Error} := \frac{\Delta v}{\Delta t}$ beschleunigt. Sind $s(t) := (x(t), y(t), \theta(t))^T$, $v(t) := (v_x(t), v_y(t), \omega(t))^T$ und $a(t) := (a_x(t), a_y(t), \alpha(t))^T$ Pose, egozentrische Geschwindigkeit und gesteuerte egozentrische Beschleunigung des Roboters zum Zeitpunkt t, dann sind Pose und Geschwindigkeit zum Zeitpunkt $t + \Delta t$

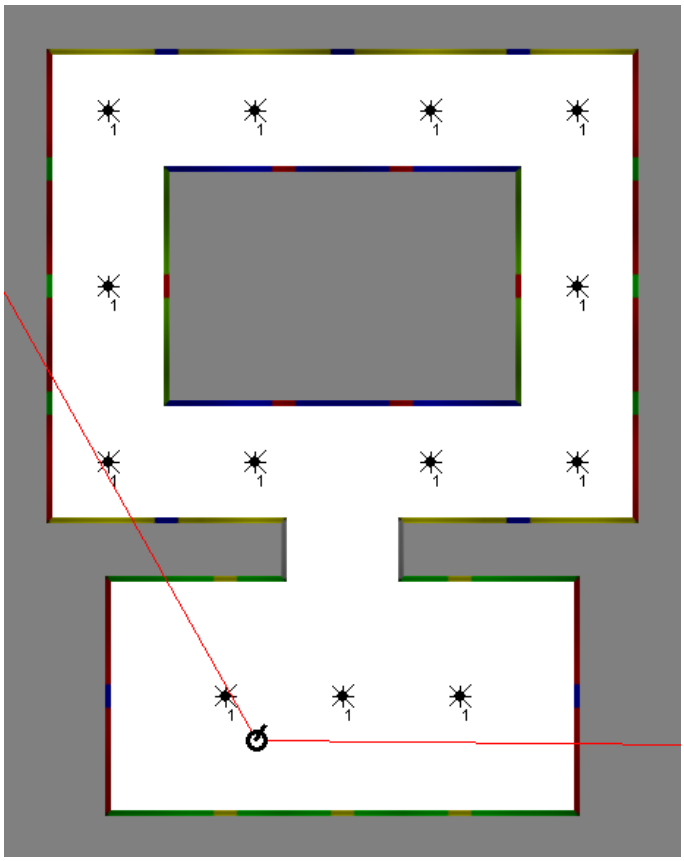

Abbildung 4.1: Beispiel einer Simulationsumgebung. Die Umgebung setzt sich aus parallelen und orthogonalen Liniensegmenten zusammen, die farbig texturiert sind. Die Lichtquellen sind als Sterne mit ihrer Leuchtstärke B dargestellt. Die Pose des Roboters ist als Kreis mit Orientierungsindikator illustriert. Der maximale Sichtwinkelbereich ist durch die roten Linien angegeben.

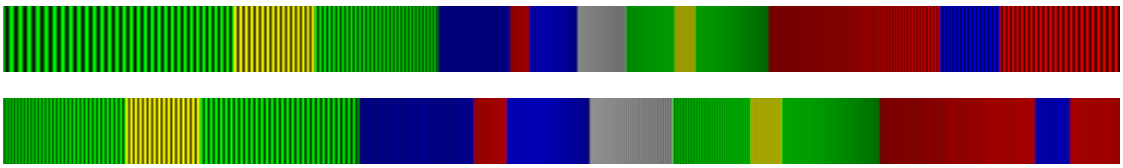

Abbildung 4.2: Illustration eines unverzerrten (oben) und eines verzerrten (unten) eindimensionalen Bildes der Umgebungssimulation. Aufgrund der projektiven Abbildung erscheinen am Bildrand des unverzerrten Bildes die geradlinigen Umgebungsstrukturen stark gestreckt. Durch die radiale Verzerrung wird dieser Effekt vermindert. Die Messungen wurden in der Pose des Roboters in Abb. 4.1 durchgeführt. Die sinusoidale Texturierung dient zur Erzeugung feiner Strukturen, die in der Merkmalsdetektion ignoriert werden sollen.

gegeben durch

$$
\begin{aligned}
v(t+\Delta t) &= v(t) + \int_t^{t+\Delta t} a(t')dt' \\
s(t+\Delta t) &= \begin{pmatrix} x(t) + \int_t^{t+\Delta t} v_x(t')\cos(\theta(t')) - v_y(t')\sin(\theta(t'))dt' \\ y(t) + \int_t^{t+\Delta t} v_x(t')\sin(\theta(t')) + v_y(t')\cos(\theta(t'))dt' \\ \theta(t) + \int_t^{t+\Delta t} \omega(t')dt' \end{pmatrix}
\end{aligned}
$$

Während eines Simulationsschrittes ändert sich die Zielgeschwindigkeit nicht. Unter der Annahme, dass die Beschleunigung instantan auf die aktuelle Geschwindigkeit wirkt, können wir die Bewegungsgleichungen durch

$$
\begin{aligned}
v_{t+\Delta t} &\approx v_t + a_{Error,t}\Delta t + \epsilon_t = v(t) + \Delta v + \epsilon_t \\
s_{t+\Delta t} &\approx \begin{pmatrix} x_t + (v_{x,t+\Delta t}\cos(\theta_t) - v_{y,t+\Delta t}\sin(\theta_t))\Delta t \\ y_t + (v_{x,t+\Delta t}\sin(\theta_t) + v_{y,t+\Delta t}\cos(\theta_t))\Delta t \\ \theta_t + \omega_{t+\Delta t}\Delta t \end{pmatrix}
\end{aligned}
$$

in einer guten Näherung approximieren.

Der simulierte Roboter navigiert in der Umgebung durch Abarbeiten einer Liste von Zielposen. Die Zielgeschwindigkeiten werden abhängig von der Distanz d zur aktuellen Zielpose und einem Schwellwert $\delta_{targetpose}$ gesetzt:

$d \geq \delta_{targetpose}$**:** Der Roboter richtet sich in der Orientierung zur Zielpose aus. Falls die Zielpose in der Front des Roboters liegt, wird die Translationsgeschwindigkeit proportional zum egozentrischen Differenzvektor zur Zielpose gesetzt.

$d < \delta_{targetpose}$**:** Translations- und Rotationsgeschwindigkeit des Roboters werden proportional zur egozentrischen Differenz zur Zielpose gesteuert.

Befindet sich der Roboter mit ausreichender Genauigkeit in der Zielpose, wird zur nächsten Zielpose übergegangen.

4.3 Eindimensionale Bildmessung

Während der Roboter in der simulierten Umgebung navigiert, werden an den Wandsegmenten, die in der aktuellen Pose des Roboters sichtbar sind, eindimensionale YUV-Bilder mit einer vorgegebenen Frequenz $f_{Bildaufnahme}$ gemessen.

Die Bildaufnahme erfolgt durch Projektion der Umgebungsstruktur auf eine imaginäre Bildebene. Sei $p_g = (x_g, y_g)^T$ ein Punkt in globalen kartesischen Koordinaten und $s_t = (x_t, y_t, \theta_t)^T$ die Pose des Roboters. Relativ zum Roboter besitzt p_g die Koordinaten

$$p_l = (x_l, y_l)^T = \mathit{localtransform}(p_g, s_t) = (R(-\theta_t)(p_g - (x_t, y_t)^T).$$

Durch Projektion des Punktes auf eine imaginäre Bildebene parallel zur lokalen y-Achse im Abstand $f = 1$ zum Ursprung erhält man die unverzerrte Bildkoordinate

$$x_u = \mathit{project1D}(p_l) = \frac{y_l}{x_l}$$

Für das spätere SLAM-Verfahren ist es nützlich, Landmarken über einen weiten Blickwinkelbereich zu observieren. Für diesen Zweck eingesetzte reale Weitwinkelobjektive

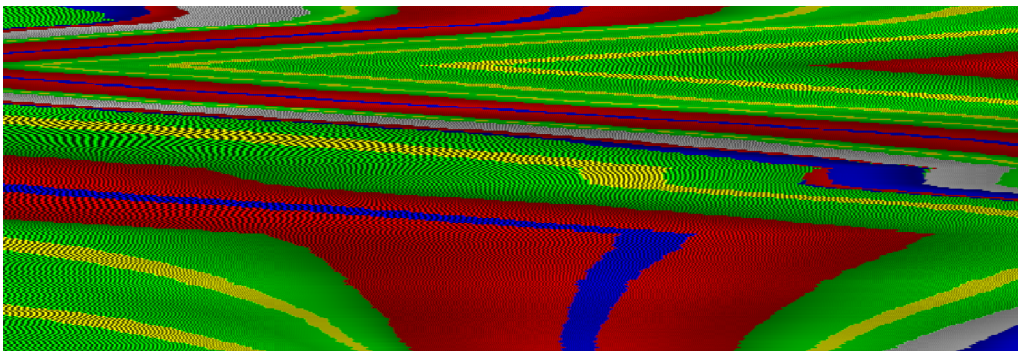

Abbildung 4.3: Beispiel von Bildmessungen mit einer Rate $f_{Bildaufnahme} = 5\text{Hz}$ während sich der Roboter durch die Umgebung bewegt. Die Bilder sind zeitlich aufeinanderfolgend von unten nach oben angeordnet.

verzerren das Bild radial und tangential. Zudem werden die geradlinigen Umgebungsstrukturen durch die projektive Abbildung bei einem weiten Blickwinkelbereich am Bildrand stärker in ihrer Ausdehnung gestreckt als in der Bildmitte (siehe Abb. 4.2). Aus diesen Gründen wird ein radial verzerrtes Bild erzeugt. Wir verwenden das folgende Modell, da es in guter Näherung invertierbar ist [31]:

$$x_d = distort(x_u) = \frac{x_u}{\sqrt{1 + 2K_{distort}x_u^2}}$$
$$x_u = undistort(x_d) = \frac{x_d}{\sqrt{1 - 2K_{distort}x_d^2}}$$

Sei α_{FOV} der Sichtwinkelbereich des Roboters. Wir wählen den Verzerrungsparameter $K_{distort}$ derart, dass $x_d = 1$ für $x_u = \tan(\frac{1}{2}\alpha_{FOV})$ gilt, um den sichtbaren Wertebereich von x_d in das Intervall $[-1, 1]$ zu normalisieren. Verzerrte Bildkoordinate und pixelwertiger Ort x_p im Bild stehen damit durch $x_p = \frac{N}{2}(x_d + 1)$ mit Bildgröße N in Beziehung.

Um Aliasing-Effekte zu vermeiden, werden die RGB-Farbwerte der Bildpixel durch gewichtetes Mitteln mehrerer Messungen um den eigentlichen Blickwinkel des Pixels gebildet, wobei die Gewichte gaußverteilt sind. Das erhaltene RGB-Bild wird anschließend saturiert, indem aus der Menge der Pixelfarbwerte zuerst 1% der Pixel mit höchsten Werten in einem der Kanäle entfernt werden, um robust gegenüber Ausreissern zu sein. Die RGB-Werte im Bild werden schliesslich mit $\frac{1}{K_{\max}}$ skaliert, wobei $K_{\max}$ der maximale Farbwert in den Kanälen der von Ausreissern befreiten Pixelmenge ist.

Die Darstellung des Farbraums in der YUV-Basis liefert eine Trennung von Luminanz und Chrominanz. Während die Y-Achse der Helligkeit einer Farbe entspricht, wie sie vom Menschen wahrgenommen wird, können die Chrominanz-Achsen U und V als Blau-Gelb- bzw. Rot-Grün-Balance aufgefasst werden.

Da die Bildgenerierung nicht in Echtzeit ausgeführt werden kann, wird das erzeugte Bild zusammen mit den Kontrolleingaben seit der letzten Messung und einem Zeitstempel gespeichert. Diese Daten dienen später als Eingabe für die Bildverarbeitung und das SLAM-Verfahren. Abb. 4.3 illustriert eine Sequenz von eindimensionalen Bildmessungen in einem Bildstapel.

5 Detektion, Beschreibung und Verfolgung von Bildmerkmalen

In den eindimensionalen YUV-Bildern werden punktförmige Merkmale detektiert, die im SLAM-Verfahren als Landmarkenobservationen verwendet werden. Als strukturgebende Merkmale extrahieren wir Kontraste in Farbe und Helligkeit, die durch Übergänge zwischen Wandsegmenten und durch Verdeckungen hervorgerufen werden können. Wir bezeichnen diese Kontraste als Kanten. Weitere Merkmale sollen in uniformen Ausdehungen zwischen komplementären Kontrasten in Farbe und Helligkeit gefunden werden, die wir als Blobs bezeichnen. Wandsegmente mit nahezu gleichförmiger Beleuchtung werden also auch als Blobs detektiert.

Eine wesentliche Anforderung an die Merkmale für die Verwendung im SLAM-Verfahren ist die invariante Beschreibung bei großen Skalen- und Blickwinkeländerungen. Dazu werden Merkmale in ihrer charakteristischen Skala detektiert. Durch die Festlegung auf einen eingeschränkten Skalenbereich im Bild tragen nur solche Strukturen der Umgebung zum Umgebungsmodell bei, die aus Sicht des Roboters eine erhebliche Ausdehnung besitzen.

Es werden zunächst interessante Bildstellen und charakteristische Skalen von Kanten und Blobs detektiert. Anschließend werden diese Merkmale in ihrer Skala beschrieben. Als Hinweis für die Datenassoziation im SLAM-Verfahren werden schließlich Korrespondenzen zwischen Bildmerkmalen in zeitlich benachbarten Bildern hergestellt.

Die Menge der Merkmale bezeichnen wir als $\mathcal{M} := \{m_k\}, k \in \{1, \ldots, K_M\}$. Jedes Merkmal

$$m_k := (p_{m_k}, t_{m_k}, d_{m_k}, c_{m_k}, \tau_{m_k})$$

besteht aus dem detektierten Ort p_{m_k}, der detektierten Skala t_{m_k}, dem Deskriptor d_{m_k}, der Detektionssicherheit $c_{m_k} \in [0, 1]$ und dem Merkmalstyp $\tau_{m_k} \in \{Kante, Blob\}$.

5.1 Merkmalsdetektion in Ort und Skala

Umgebungsstrukturen erscheinen unter unterschiedlichen Blickwinkeln und in verschiedenen Distanzen durch die Eigenschaften der projektiven Abbildung und Linsenverzerrungseffekte in unterschiedlichen Größen im Bild. Die Größe einer abgebildeten Struktur wird als Skala des Merkmals bezeichnet. Damit Merkmale translations- und skaleninvariant beschrieben werden können, muss daher neben dem Ort der Merkmale im Bild auch deren charakteristische Skala detektiert werden.

Um interessante Bildstellen in einem D-dimensionalen Bild $f : \mathbb{R}^D \to \mathbb{R}$ zu detektieren, werden üblicherweise Bildstellen bestimmt, die einen Differentialoperator $\mathcal{D}_{Space}$ lokal maximieren [32]. Um die Skala einer interessanten Bildstelle zu detektieren, wird ebenfalls ein Differentialoperator lokal maximiert, allerdings entlang einer zusätzlichen Skalendimension des Bildes.

Die Skalenraumdarstellung $L : \mathbb{R}^D \times \mathbb{R}_+ \to \mathbb{R}$ eines Bildes f ist durch Faltung von f mit gaußförmigen Kernfunktionen $g : \mathbb{R}^D \times \mathbb{R}_+ \to \mathbb{R}$ beliebiger Bandbreite $t \in \mathbb{R}_+$ gegeben:

$$\begin{aligned} &L(x,0) := f(x), \\ &L(x,t) := (g(\cdot,t) * f)(x) = \int_{\xi \in \mathbb{R}^D} g(\xi,t) f(x-\xi) d\xi, \forall t \in \mathbb{R}_+ : t > 0, \end{aligned} \tag{5.1}$$

mit

$$g(x,t) := \frac{1}{(2\pi t)^{D/2}} \exp\left(-\frac{x_1^2 + \ldots + x_D^2}{2t}\right), \forall t \in \mathbb{R}_+ : t > 0$$

Die Ableitung innerhalb einer Skala t entlang der Ortsdimensionen ist gegeben durch

$$L_{x^\alpha}(\cdot,t) := \partial_{x^\alpha} L(\cdot,t) = \partial_{x^\alpha}(g(\cdot,t) * f) = \partial_{x^\alpha} g(\cdot,t) * f = g_{x^\alpha}(\cdot,t) * f,$$

wobei $\alpha := (\alpha_1 \ \ldots \ \alpha_D)$ die Ordnungen der partiellen Ableitungen in den einzelnen Ortsdimensionen angibt.

Im Gegensatz zu gaußförmigen Faltungskernen integrieren die differentiellen Faltungskerne $g_{x^\alpha}(\cdot,t)$ über $\mathbb{R}^D$ in unterschiedlichen Skalen nicht zur selben Norm. Damit Ableitungen auch über Skalen vergleichbar sind, müssen sie entsprechend der Ordnung der Ableitung und der Bandbreite des Gaußkerns normalisiert werden. Die γ-normalisierte Ableitung r-ter Ordnung eines Gaußkerns ist definiert als

$$g_{\xi^r}(\cdot,t) := t^{r\gamma/2} g_{x^r}(\cdot,t). \tag{5.2}$$

Ziel der Normalisierung ist es, die Ableitungen in den Skalen zu konstanter L_p-Norm zu normalisieren, d.h. $\forall t_1, t_2 \in \mathbb{R}_+$:

$$\|g_{\xi^r}(\cdot,t_1)\|_p = \|g_{\xi^r}(\cdot,t_2)\|_p .$$

Die Parameter p und γ stehen durch

$$p = \frac{1}{1 + \frac{r}{D}(1-\gamma)}$$

in Beziehung.

In rechnergestützten Anwendungen liegt das Bild $f : \mathbb{Z}^D \to \mathbb{R}$ an diskreten, abgetasteten Stellen vor. Die Skalenraumdarstellung eines diskreten Bildes, $L : \mathbb{Z}^D \times \mathbb{R}_+ \to \mathbb{R}$, wird durch Faltung von f mit dem diskreten Analogon $T : \mathbb{Z}^D \times \mathbb{R}_+ \to \mathbb{R}$ zum kontinuierlichen Gaußkern erzeugt. Für eindimensionale Bilder ist der Skalenraum definiert durch

$$\begin{aligned} L(x,t) &:= \sum_{n \in \mathbb{Z}} T(n,t) f(x-n), \text{mit} \\ T(n,t) &:= e^{-t} I_n(t), \end{aligned} \tag{5.3}$$

wobei I_n hier modifizierte Besselfunktionen gerader Ordnung sind.

Interessante Stellen in Ort und Skala werden nun gefunden, indem Stellen im Skalenraum bestimmt werden, an denen sowohl ein Differentialoperator $\mathcal{D}_{Space}$ entlang der Ortsdimensionen des Bildes als auch ein Differentialoperator $\mathcal{D}_{Scale,norm}$ entlang der Skalendimension lokal maximiert werden:

$$\begin{aligned} &\nabla(\mathcal{D}_{Space} f) = 0 \\ &\nabla^2(\mathcal{D}_{Space} f) \ \textit{negativ definit} \\ &\partial_t(\mathcal{D}_{Scale,norm} f) = 0 \\ &\partial_{tt}(\mathcal{D}_{Scale,norm} f) \leq 0 \end{aligned} \tag{5.4}$$

Der Operator $\mathcal{D}_{Scale,norm}$ setzt sich möglicherweise nichtlinear aus γ-normalisierten Ableitungen zusammen.

5.2 Effiziente Mehrskalenrepräsentation

In einer naiven Umsetzung von Gl. (5.3) müsste das Bild f zur Betrachtung einer Skala t mit dem Kern $T(n,t)$ gefaltet werden. Für eine effiziente Erzeugung einer Mehrskalendarstellung des Bilds in diskreten Skalen ist dieser Ansatz nicht geeignet, da für die Erzeugung jedes Skalenbilds Laufzeitaufwand in $O(N^2)$ nötig ist, wenn N die Anzahl der Bildpunkte ist.

Eine alternative Darstellung im eindimensionalen Fall ergibt sich aus der äquivalenten Definition des Skalenraums als Lösung der Diffusionsgleichung

$$\frac{\partial L}{\partial t} = \frac{1}{2}\delta_{xx} * L$$

mit dem Differenzenoperator zweiter Ordnung $\delta_{xx} = (1, -2, 1)$.

Durch Anwendung der Eulermethode mit Schrittweite Δt erhält man

$$\begin{aligned} L(\cdot, t + \Delta t) &= L(\cdot, t) + \Delta t \frac{1}{2}\delta_{xx} * L(\cdot, t) \\ &= \left(\frac{\Delta t}{2}, 1 - \Delta t, \frac{\Delta t}{2}\right) * L(\cdot, t) \end{aligned}$$

Nach [33], Prop. 10, erfüllt der Faltungskern $\left(\frac{\Delta t}{2}, 1 - \Delta t, \frac{\Delta t}{2}\right)$ für $\Delta t \leq \frac{1}{2}$ die Eigenschaften eines Skalenraumkerns, insbesondere Unimodalität. Für $\Delta t = \frac{1}{2}$ entspricht dieser Kern dem Binomialkern der Länge 3, $\left(\frac{1}{4}, \frac{1}{2}, \frac{1}{4}\right)$. Mit diesem Faltungskern ist es möglich, eine Mehrskalenrepräsentation des Bildes in diskreten Skalenschritten Δt zu erzeugen.

Eine wichtige Beobachtung ist, dass mit zunehmender Skala t die lokale Redundanz entlang der Ortsdimension zunimmt. Dies wird in Pyramidenverfahren ausgenutzt, in denen eine Mehrskalenrepräsentation durch sukzessives Glätten und Verringern der Auflösung erzeugt wird. Durch Verwendung von Kernen geringer Breite kann diese effizient generiert werden. Zusätzlich wird der Aufwand von Bildverarbeitungsoperatoren mit zunehmender Skala aufgrund der abnehmenden Bildgröße reduziert. Allerdings muss in diesen Verfahren die Schrittgröße entlang der Skalendimension vorsichtig gewählt werden, damit durch die Auflösungsverringerung keine zusätzlichen Strukturen erzeugt werden.

Eine offensichtliche Lösung dieses Problems besteht darin, erst nach einer gewissen Anzahl an Glättungsoperationen einen Dezimierungsschritt durchzuführen, und auf diese Weise eine überabgetastete Pyramide bzw. hybride Mehrskalenrepräsentation zu erzeugen [32].

Zunächst definieren wir den Glättungsoperator

$$\mathit{DeltaSmooth}(L, \Delta t, K) := \left(\frac{\Delta t}{2}, 1 - \Delta t, \frac{\Delta t}{2}\right)^K * L$$

als Konkatenation von K Faltungen des Bilds L mit dem Faltungskern $\left(\frac{\Delta t}{2}, 1 - \Delta t, \frac{\Delta t}{2}\right)$. Faltung von L mit Binomialkernen der Länge 3 bzw. 5 entspricht also den Operatoren

$$\begin{aligned} \mathit{Bin3Smooth}(L) &:= \mathit{DeltaSmooth}(L, \frac{1}{2}, 1) = \frac{1}{4}(1, 2, 1) * L, \text{bzw.} \\ \mathit{Bin5Smooth}(L) &:= \mathit{DeltaSmooth}(L, \frac{1}{2}, 2) = \frac{1}{16}(1, 4, 6, 4, 1) * L. \end{aligned}$$

Der Dezimierungsoperator

$$SubSample(L) := (L_{2k})_{k \in \{1,\ldots,N/2\}}$$

erzeugt aus einem Bild der Größe N ein Bild der Größe $N/2$ durch Auslassung jedes zweiten Bildelements.

In einer Bildpyramide werden nun die Ebenen $L_i, i \in \{1, \ldots, I\}$ durch rekursives Anwenden von Glättungs- und Dezimierungsoperatoren erzeugt:

$$L_i := \begin{cases} f & \text{, falls } i = 1 \\ SubSample(DeltaSmooth(L_{i-1}, \Delta t, K)) & \text{, sonst} \end{cases}$$

Eine überabgetastete Bildpyramide besteht aus I Ebenen, die jeweils J Unterebenen derselben Abtastrate enthalten. Die Unterebenen $L_{i,2} \ldots L_{i,J}$ einer Ebene i werden durch sukzessives Glätten erzeugt, wobei die erste Unterebene $L_{i,1}$ jeder Ebene i aus der letzten Unterebene $L_{i-1,J}$ der vorherigen Ebene $i-1$ durch Glättung und Dezimierung hervorgeht:

$$L_{i,j} := \begin{cases} f & \text{, falls } i = 1 \text{ und } j = 1 \\ SubSample(DeltaSmooth(L_{i-1,J}, \Delta t, K)) & \text{, falls } i > 1 \text{ und } j = 1 \\ DeltaSmooth(L_{i,j-1}, \Delta t, K) & \text{, falls } j \in \{2, \ldots, J\} \end{cases}$$

Wird eine Mehrskalenrepräsentation lediglich durch Kaskadierung von Glättungsoperatoren der Skalenschrittweite Δt erzeugt, lässt sich die Skala der einzelnen Ebenen leicht angeben. Die Varianz des Faltungskerns $\left(\frac{\Delta t}{2}, 1 - \Delta t, \frac{\Delta t}{2}\right)$ beträgt Δt. Durch K-fache Kaskadierung dieses Faltungskerns ergibt sich ein Faltungskern, dessen Varianz exakt $K\Delta t$ beträgt.

Eine Ebene (i, j) in einer überabgetasteten Pyramide wird durch Anwendung einer Reihe von Glättungs- und Dezimierungsoperatoren auf das Bild f erzeugt. Wegen

$$((c_{-N}, \ldots, c_N) * SubSample(f))(x) = SubSample((c'_{-2N}, \ldots, c'_{2N}) * f)(x) \tag{5.5}$$

mit

$$c'_n := \begin{cases} c_{\frac{n}{2}} & \text{, falls } n = 2k, k \in \{-N, \ldots, N\} \\ 0 & \text{, sonst} \end{cases}$$

kann jede beliebige Konkatenation von Glättungs- und Dezimierungsoperatoren als Verkettung von Faltungen und anschließender Dezimierung aufgefasst werden. Die Verkettung von Faltungen, die der Erzeugung der Ebene (i, j) entspricht, wird als äquivalenter Faltungskern $C^{(i,j)}$ bezeichnet. Die Skala $t_{i,j}$ der Ebene (i, j) lässt sich als Varianz dieses äquivalenten Faltungskerns, $t_{i,j} = var(C^{(i,j)})$, ermitteln. Durch Anwendung des Glättungsoperators auf die Ebene (i, j) vergrößert sich die Skala demnach um $h(i)^2 K\Delta t$, wobei der Gitterabstand $h(i)$ der Dezimierungsrate im Bezug zum Ausgangsbild f entspricht.

Zur Bestimmung der Approximation der r-ten Ableitung einer Ebene (i, j) wird die Ebene mit dem Differenzenkern $\mathcal{D}_{x^r}$ r-ter Ordnung unter Berücksichtigung des Gitterabstands der Ebene gefaltet:

$$\mathcal{D}_{x^r} := \frac{1}{h(i)^r} \delta_{x^r}$$

mit

$$\delta_{x^r} := \begin{cases} (\delta_{xx})^{\frac{r}{2}} & \text{, falls } r \text{ gerade, und} \\ \delta_x * \delta_{x^{r-1}} & \text{, falls } r \text{ ungerade.} \end{cases}$$

i	$t_{i,1}$	$t_{i,2}$	$t_{i,3}$	$h(i)$
1	1.0	2.0	3.0	1
2	4.0	8.0	12.0	2
3	16.0	32.0	48.0	4
4	64.0	128.0	192.0	8
5	256.0	512.0	768.0	16
6	1024.0	2048.0	3072.0	32

Tabelle 5.1: Skalen und Gitterabstände der Ebenen $(1,1)$ bis $(6,3)$ einer $Bin5(3)$-Pyramide.

und den Differenzenoperatoren erster und zweiter Ordnung $\delta_x = \left(-\frac{1}{2}, 0, \frac{1}{2}\right)$ bzw. δ_{xx}. Aufgrund von Gl.(5.5) kann die Ableitungsapproximation der Ebene (i,j) durch Faltung mit einem äquivalenten Faltungskern $C_{x^r}^{(i,j)}$ und anschließender Dezimierung erzeugt werden. Eine über Skalen vergleichbare Ableitungsapproximation der Ebene (i,j) erhält man wie bereits erwähnt durch γ-Normalisierung. In einer überabgetasteten Pyramide mit Auflösungsreduktion muss der Differenzenkern $\mathcal{D}_{x^r}$ geeignet skaliert werden:

$$\mathcal{D}_{x^r,norm} := \alpha_r \mathcal{D}_{x^r}$$

In dieser Arbeit wird dem Vorschlag von Bretzner et al. [32] gefolgt, zur Skalierung die Methode der L_p-Normalisierung zu verwenden. Die Skalierung soll die L_p-Norm des normalisierten äquivalenten Faltungskerns zur Ableitungsapproximation an die L_p-Norm des gaußschen Ableitungsoperators $g_{\xi^r}(x, t_{i,j})$ anpassen:

$$\alpha_{r,l_p} := \frac{\left\| g_{\xi^r}(\cdot, t_{i,j}) \right\|_p}{\left\| C_{x^r}^{(i,j)} \right\|_p}$$

Durch Wahl von Δt, K und J kann die Abtastrate entlang der Skalendimension eingestellt werden, sodass zwischen höherer Genauigkeit und höherer Laufzeiteffizienz abgewogen werden kann. In der vorliegenden Anwendung bietet eine überabgetastete $Bin5(3)$-Pyramide mit $\Delta t = \frac{1}{2}$, $K = 2$ und $J = 3$ ausreichend Genauigkeit bei hoher Laufzeiteffizienz für die Merkmalsdetektion. Die Wahl von $\Delta t = \frac{1}{2}$ ist damit begründet, dass der äquivalente Faltungskern, der sukzessivem Falten mit Binomialkernen entspricht, eine gute Näherung zu einem kontinuierlichen Gausskern liefert. Mit einem Vorglättungsschritt durch Faltung mit einem binomialen 5-Kern ergibt sich eine überabgetastete Pyramide, deren Ebenenskalen und -gitterabstände bis zur Ebene $(6,3)$ in Tabelle 5.1 aufgeführt sind. Aus der Tabelle ist ersichtlich, dass die gewählte Pyramide in jeder Ebene (i,j) wegen $\sqrt{t_{i,j}} \geq h(i)$ ein sinnvolles Verhältnis von Dezimierungsrate zu Glättung besitzt, da die Werte der Gitterpunkte anschaulich die Werte im Bereich zu den jeweils benachbarten Gitterpunkten repräsentieren. Beispielsweise tragen die Werte im Originalbild an den Stellen der nächsten Nachbarn mindestens mit dem Gewicht $e^{-\frac{1}{2}} \approx 0.607$ zum Wert eines Gitterpunkts bei. Das Originalbild bezeichnen wir im folgenden als Ebene $(1,0)$. Abb. 5.1 illustriert Glättung und Dezimierung von Ebenen in einer $Bin5(3)$-Pyramide.

Bei der Glättung eines endlichen Bildes muss der Rand gesondert behandelt werden. Wir lösen dieses Problem, indem bei einem Zugriff ausserhalb des Bildbereichs an eine Stelle $x < 1$ bzw. $x > N$ das Bild durch Spiegelung fortgesetzt wird, d.h. es wird die Stelle $\tilde{x} = 2 - x$ bzw. $\tilde{x} = N - (x - N)$ verwendet.

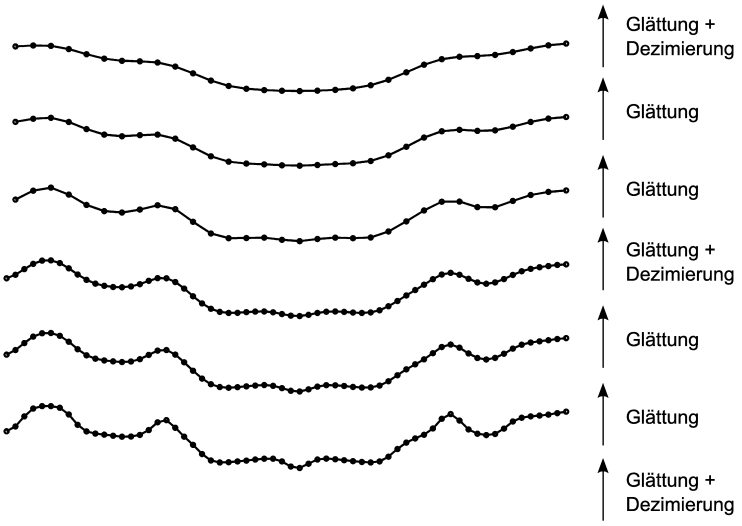

Abbildung 5.1: Illustration der sukzessiven Glättung und Dezimierung eines eindimensionalen Signals in einer $Bin5(3)$-Pyramide. Das Signal wird in jedem Glättungsschritt mit einem Binomialkern der Länge fünf geglättet. Nach jeder dritten Glättung wird das Signal um den Faktor zwei dezimiert.

5.3 Detektion punktförmiger Merkmale

Ziel der Merkmalsdetektion ist es, in einem eindimensionalen YUV-Bild Ort und Skala von signifikanten Kanten und Blobs zu detektieren. Während in [18] skaleninvariante Merkmale in eindimensionalen Bildern nur für die Herstellung von Merkmalskorrespondenzen in zwei Bildern extrahiert werden, sollen in dieser Arbeit gezielt Merkmale detektiert werden, mit denen die Struktur der Umgebung erfasst werden kann. Ausserdem wird Farbinformation hier nicht nur zur Beschreibung von Merkmalen verwendet, sondern auch zur Detektion.

Um Merkmale in Farbe und Helligkeit zu detektieren, trennen wir die YUV-Kanäle des eindimensionalen Bildes in Luminanz (Y), positive Chrominanzen (U^+ bzw. V^+) und negative Chrominanzen (U^- bzw. V^-), da ansonsten durch Glättung der Chrominanzwerte durch Überlagerung von positiven und negativen Werten Farbinformationen ausgelöscht werden. Die Kanäle können als Helligkeit (Y), Blau- (U^+), Gelb- (U^-), Rot- (V^+) und Grüntönigkeit (V^-) aufgefasst werden. Für jeden dieser Kanäle wird zur weiteren Verarbeitung eine $Bin5(3)$-Pyramide erzeugt. Da zur Detektion Differentialoperatoren verwendet werden, die sich aus ersten und zweiten Ableitungen der Kanäle zusammensetzen, werden für jede Ebene und jeden Kanal γ-normalisierte Ableitungen 1. und 2. Ordnung mit $\gamma = 1$ erzeugt. Wir bezeichnen die Ebene (i, j) des jeweiligen Kanals als $Y_{i,j}$, $U^+_{i,j}$, $U^-_{i,j}$, $V^+_{i,j}$ und $V^-_{i,j}$, und notieren die γ-normalisierten Ableitungen r-ter Ordnung der Kanäle und Ebenen mit dem Präfix $\partial^{\gamma}_{x^r}$.

5.3.1 Kantendetektion

In Anlehnung an den Harris-Eckendetektor [34] für zweidimensionale Bilder bestimmen wir Kanten als Kontraste in eindimensionalen Bildern. Harris-Ecken werden in Bildstellen

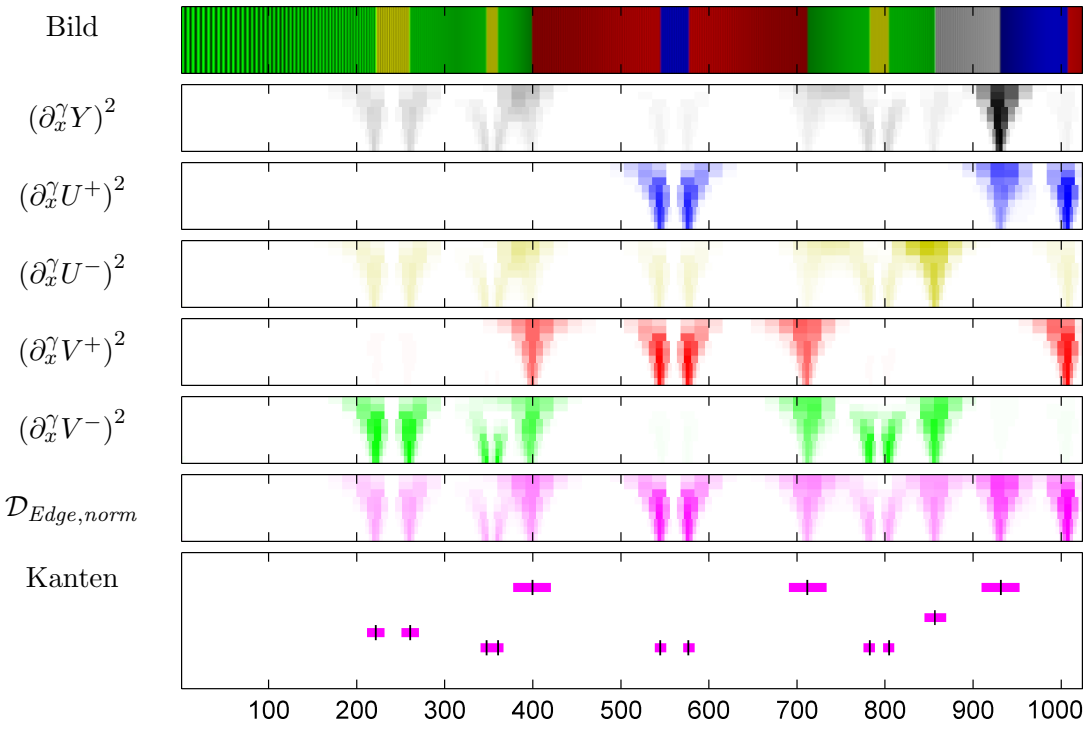

Abbildung 5.2: Illustration der ungewichteten Kantenantwort $\mathcal{D}_{Edge,norm}$ und den Antworten der Einzelkanäle in Ort und Skala. Die Kantenantwort wird durch Gewichtung am oberen Rand abgeschwächt. Kanten werden in Maxima entlang Ort und Skala in der gewichteten Kantenantwort detektiert. Die Balkenbreite einer Detektion gibt die Standardabweichung der Detektionsskala an.

mit lokal hoher Varianz in beiden Hauptachsen detektiert. Die Varianz wird durch Faltung des Bildes mit einem Gaußschen Glättungskern und Differentialkernen 1. Ordnung in x- und y-Richtung bestimmt. Mikolajczyk et al. [35] erweiterten diesen Detektor zu einem skaleninvarianten Eckendetektor, der als Harris-Laplace-Detektor bezeichnet wird. Die grundlegende Idee ist, für Extrema der lokalen Varianz in der Ortsdimension auch die Extremumseigenschaft im Laplacian of Gaussian des Bildes entlang der Skalendimension zu fordern.

Wir detektieren Kanten in möglichst mehreren Kanälen über einen festgelegten Skalenbereich $t_{Edge,start}$ bis $t_{Edge,end}$ Mit der Wahl des Skalenbereichs lässt sich steuern, ab welcher Ausdehnung der dazugehörigen Strukturseiten eine Kante detektiert werden soll. Die Endskala legt eine obere Schranke für die spätere Beschreibung der Kante fest.

Zur Detektion bilden wir den Differentialoperator

$$\mathcal{D}_{Edge,norm}(i,j,x) = \\ (\partial_x^\gamma Y_{i,j}(x))^2 + \left(\partial_x^\gamma U_{i,j}^+(x)\right)^2 + \left(\partial_x^\gamma U_{i,j}^-(x)\right)^2 + \left(\partial_x^\gamma V_{i,j}^+(x)\right)^2 + \left(\partial_x^\gamma V_{i,j}^-(x)\right)^2$$

im vektoriellen Bild über die Kanäle $f : x \longmapsto (Y(x), U^+(x), U^-(x), V^+(x), V^-(x))^T$. Da zur Skalenselektion Kantenantworten nicht über die Ränder des Skalenbereichs verglichen werden sollen, wird die Kantenantwort am oberen Skalenrand durch Gewichtung mit $\frac{1}{2}$

abgeschwächt:

$$\mathcal{D}^{w}_{Edge,norm}(i,j,x) = w_{i,j}\mathcal{D}_{Edge,norm}(i,j,x)$$

mit Gewichten

$$w_{i,j} := \begin{cases} 1 & \text{, falls } t_{i,j} \geq t_{Edge,start} \wedge t_{i,j} < t_{Edge,end} \\ \frac{1}{2} & \text{, falls } t_{i,j} = t_{Edge,end} \\ 0 & \text{, sonst.} \end{cases}$$

Mit dieser gewichteten Kantenantwort werden nach den Kriterien in Gl. (5.4) Ort und Skala von interessanten Punkten bestimmt. Zunächst detektieren wir Maxima $\{(x_k, i_k, j_k, c_k)\}$ in der Kantenantwort in jeder Ebene (i_k, j_k) der Pyramide entlang der Ortsdimension durch Vergleich der Kantenantwort in x_k mit den Kantenantworten der direkten Nachbarn. Für diese Maxima bestimmen wir Ort $\tilde{x}_k$ und Kantenantwort $\tilde{\mathcal{D}}_k := \mathcal{D}^{w}_{Edge,norm}(i,j,\tilde{x}_k)$ mit Subpixel-Genauigkeit durch Taylorexpansion 2. Ordnung. Aus der Kantenantwort $\tilde{\mathcal{D}}_k$ berechnen wir die Detektionssicherheit c_k der potentiellen Kante durch lineare Interpolation zwischen zwei Schranken $\kappa_{Edge,\min}$ und $\kappa_{Edge,\max}$:

$$c_k = \Lambda_{high}(\tilde{\mathcal{D}}_k, \kappa_{Edge,\min}, \kappa_{Edge,\max}) \text{ mit}$$
$$\Lambda_{high}(x, \kappa_{\min}, \kappa_{\max}) := \max\left(0, \min\left(1, 1 - \frac{\kappa_{\max} - x}{\kappa_{\max} - \kappa_{\min}}\right)\right).$$

Falls die Detektionssicherheit $c_k = 0$ beträgt, wird das Maximum verworfen.

Anschliessend wird für jedes gefundene Maximum in den vier benachbarten Ebenen entlang der Skalendimension überprüft, ob ein weiteres Maximum mit grösserer Kantenantwort existiert. Wird ein stärkeres Maximum in einer benachbarten Skala gefunden, wird das untersuchte Maximum verworfen. Auf diese Weise erhält man interessante Stellen in Ort und Skala für Kanten.

Aufgrund der Glättung und der Festlegung auf eine untere Skala zur Detektion entspricht der extrahierte Ort einer Kante am unteren Skalenrand nicht dem tatsächlichen Ort im Bild. Zur Lokalisierung der Kante laufen wir durch Gradientenabstieg entlang der Skalendimension bis zur untersten Ebene entlang des Grats in der ungewichteten Kantenantwort. Ist der Wert der Kantenantwort im Grat geringer als ein Bruchteil der Kantenantwort der untersuchten Kante, wird das Verfolgen abgebrochen. Es werden mehrere Grate verfolgt, falls kein Gradient zur nächstniederen Skala in benachbarten Orten signifikant der größte ist. Werden auf diese Weise mehrere Maxima entlang der Ortsdimension in der niedersten Skala gefunden, wird die Kante aufgrund ihrer schlechten Lokalisierung verworfen. Konnte nur ein Maximum bestimmt werden und existiert kein weiteres Maximum auf der niedersten Skala in lokaler Nachbarschaft, wird der subpixelgenaue Ort des Maximums durch Taylorexpansion 2. Ordnung bestimmt. Die lokale Nachbarschaft, in der nach Maxima gesucht wird, ist durch die σ-Umgebung der untersten Detektionsskala gegeben.

Auch für Kanten in groben Skalen wird auf diese Weise der Grat in der ungewichteten Kantenantwort bis zur niedersten Skala verfolgt. Kann kein Grat bis zur untersten Skala verfolgt werden, wird die Kante durch einen flachen Helligkeits- bzw. Farbgradienten verursacht und wird daher verworfen. Wurde nur eine Spur verfolgt, darf kein Wert entlang des Grats existieren, der größer als die Kantenantwort der untersuchten Kante ist, damit keine multiplen Kantenmerkmale an derselben Strukturkante im Bild erzeugt werden können. Ist dies nicht der Fall, wird der Ort der Kante durch den subpixelgenauen

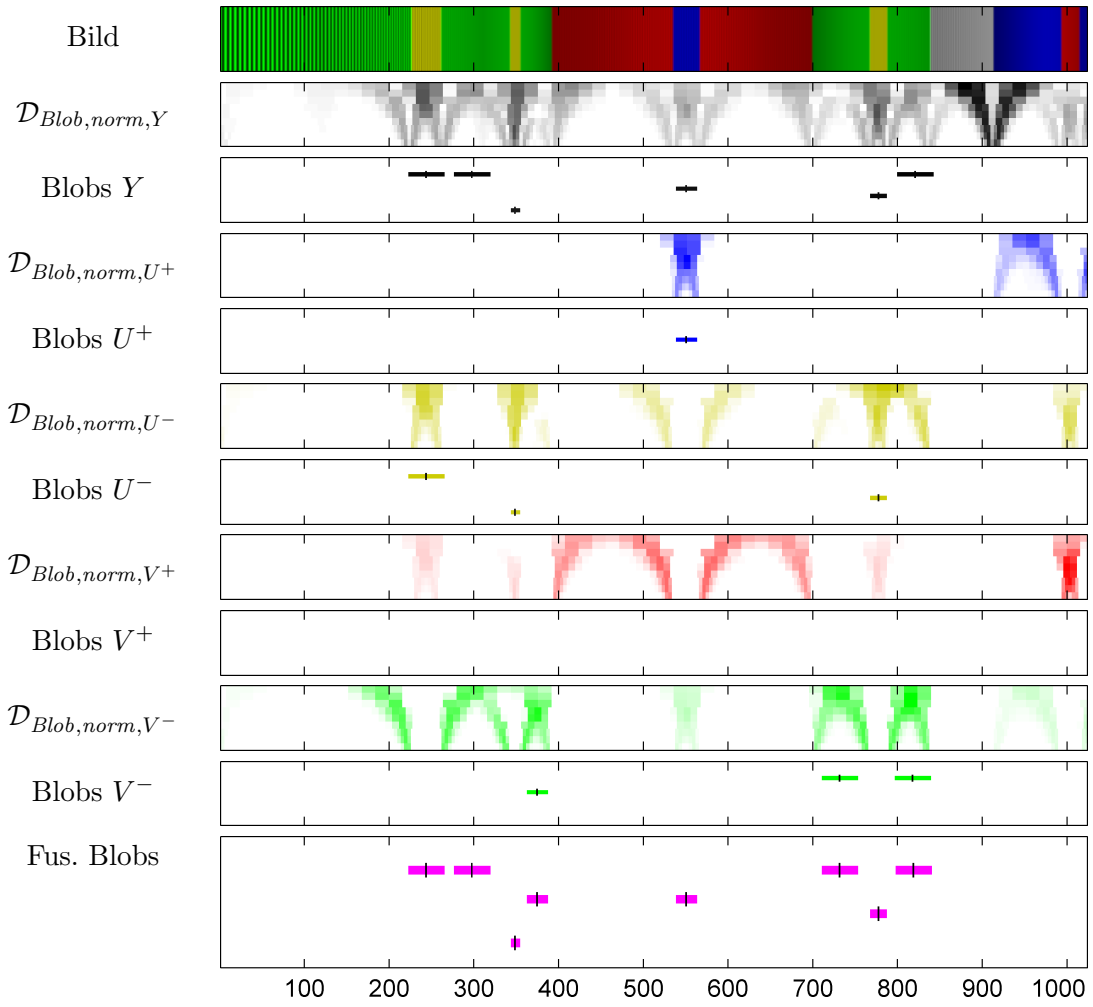

Abbildung 5.3: Illustration der Blobantworten $\mathcal{D}_{Blob,norm,K}$ in den Einzelkanälen K. Blobs werden in Maxima entlang Ort und Skala in der Blobantwort detektiert. Die detektierten Blobs in den Einzelkanälen werden zu mehrkanäligen Blobs fusioniert. Die Balkenbreite einer Detektion gibt die Standardabweichung der Detektionsskala an.

Ort des Maximums auf der niedersten Skala ersetzt. Bei mehrern verfolgten Graten wird der subpixelgenaue Ort des Merkmals auf der ursprünglichen Detektionsskala durch Taylorapproximation 2. Ordnung bestimmt.

5.3.2 Blobdetektion

Analog zur Detektion von SIFT oder SURF-Merkmalen [1, 36] in zweidimensionalen Bildern, detektieren wir Blobs in kontrastarmen Bildbereichen zwischen komplementären Kontrasten. Betrachtet man die zweite Ableitung eines Bilds über Skala und Ort, finden sich Ort und charakteristische Skala eines Blobs an Stellen, an denen sich durch die Glättung Maxima bzw. Minima in der zweiten Ableitung überlagern. Im zweidimensionalen Bild werden Extrema des Laplacian of Gaussians entlang Ort- und Skalendimension bestimmt.

Auch für die Detektion von Blobs legen wir einen Skalenbereich $t_{Blob,start}$ bis $t_{Blob,end}$ fest. Im Gegensatz zur Kantenantwort definieren wir für Blobs Differentialoperatoren in den Einzelkanälen. Im Helligkeitskanal unterscheiden wir nicht zwischen Minima und Maxima in der zweiten Ableitung, sodass Blobs detektiert werden können, die sich von ihrer Umgebung sowohl als hellere als auch als dunklere Bereiche abheben:

$$\mathcal{D}_{Blob,norm,Y}(i,j,x) = \left|\partial^{\gamma}_{x^2} K_{i,j}(x)\right| .$$

In den Farbkanälen betrachten wir nur Minima in der zweiten Ableitung als saliente Blobmerkmale, welches Strukturen mit hervorgehobener Farbwertigkeit des Kanals sind:

$$\mathcal{D}_{Blob,norm,K}(i,j,x) = \partial^{\gamma}_{x^2} K_{i,j}(x)$$

in den Einzelkanälen $K \in \{U^+, U^-, V^+, V^-\}$.

Weil die Blobantworten in den Einzelkanälen nicht direkt vergleichbar sind, werden zunächst anhand dieser Blobantwort interessante Stellen $\{b_k = (x_k, i_k, j_k, c_k)^T\}$ in Maxima entlang Ort und Skala detektiert. Dazu wird jede Ebene in der Ortsdimension durchlaufen und für jede Stelle überprüft, ob sie maximale Blobantwort unter den direkten Nachbarn in Ort und Skala aufweist. Ist dies der Fall, wird der subpixelgenaue Ort $\tilde{x}_k$ des Maximums bestimmt, und es wird überprüft, ob in der ersten Ableitung zwischen $x_k - 1$ und x_k oder zwischen x_k und $x_k + 1$ ein signifikanter Nulldurchgang besteht. Aus der Differenz zwischen den Blobantworten in den Stellen $x_k - 1$ und x_k bzw. x_k und $x_k + 1$ berechnen wir die Werte c_{zero} für die Sicherheit des Nulldurchgang durch lineare Interpolation zwischen zwei Schranken für jedes Stellenpaar.

Existiert ein signifikanter Nulldurchgang, d.h. $c_{zero} > 0$, wird auf der Skala $t = \sigma^2$ in der lokalen 2σ-Nachbarschaft der Detektion nach den Nebenextrema in der zweiten Ableitung gesucht. Anschaulich wird ein Blobkandidat in Skala und Ort detektiert, in denen die zweite Ableitung dem Differentialoperator lokal am besten entspricht. Die Anwendung des Differentialoperators in einer Ebene korrespondiert zur Faltung der Ebene mit der zweiten Ableitung eines Gaußkerns, die neben dem zentralen Extremum zwei Nebenextrema aufweist, die zum Extremum im Zentrum entgegengesetzte Polarität besitzen. Können diese Nebenextrema gefunden werden, setzen wir das Minimum im Betrag der Blobantworten in den Nebenextrema mit dem Betrag der Blobantwort an der detektierten Stelle ins Verhältnis. Aus dem Verhältnis bestimmen wir die Sicherheit in der Auffindung der Nebenextrema durch Interpolation zwischen zwei Schranken. Die Sicherheit c_{cand} in der Detektion des Blobkandidaten ergibt sich als Minimum zwischen Nulldurchgangssicherheit und Nebenextremasicherheit.

Ist diese Sicherheit von Null verschieden, bestimmen wir die Blobstärke $S_{Blob}(i,j,\tilde{x}_k)$ am subpixelgenauen Ort durch Taylorexpansion 2. Ordnung der Blobantwort im Einzelkanal K und anschließender Anwendung einer Sigmoidalfunktion:

$$S_{Blob}(i,j,\tilde{x}_k) = \sigma\left(c_{cand}\tilde{\mathcal{D}}_{Blob,norm,K}(i,j,\tilde{x}_k), a_{Blob}, c_{Blob}\right), \text{ mit}$$
$$\sigma(v,a,c) := \frac{1}{1+e^{-a(v-c)}}.$$

Die Blobantwort wird mit der Detektionssicherheit diskontiert, um den Einfluss in der nachfolgenden Fusion der Einzelkanäle proportional zur Unsicherheit zu vermindern. Durch sinnvolle Wahl von a und c erhält man ein Maß zum Vergleich der Blobstärke an den interessanten Stellen zwischen den Einzelkanälen. Um zu gewährleisten, dass keine

redundanten interessanten Stellen gefunden werden, überprüfen wir für jede interessante Stelle, dass in den vier benachbarten Ebenen und den benachbarten Orten keine weiteren interessanten Stellen mit höherer subpixelgenauer Blobantwort gefunden wurden.

Die auf diese Weise bestimmten Blobdetektionen $\{b_k\}, k \in \{1, \ldots, K\}$ in den Einzelkanälen werden durch ein Votierungsverfahren zu mehrkanäligen Blobs fusioniert. Wir bilden eine Pyramide derselben Diskretisierung wie die Einzelkanalspyramiden, um Interessantheit zu akkumulieren. Jeder Blob eines Einzelkanals votiert für die Interessantheit in seiner lokalen Nachbarschaft, die im Ort durch die Dezimierungsrate $h(i)$ und in der Skala durch den Ebenenabstand gegeben ist. In diesem Interessantheitsbild werden die Maxima entlang Ort und Skala bestimmt, indem auf jeder Ebene der aktuelle Ort mit seinen direkten Nachbarn in Ort und Skala verglichen wird. Wurde ein Maximum gefunden, werden die beteiligten Blobs aus den Einzelkanälen zusammengeführt, indem das gewichtete Mittel für Ort und Skala der Blobs gebildet wird. Das Gewicht eines Blobs ist durch die Blobstärke gegeben. Die subskalengenaue Skala des fusionierten Blobs wird auf die nächste repräsentierte Skala in der Pyramide gerundet. Die Detektionssicherheit c_k des fusionierten Blobs schätzen wir aus der mittleren Blobstärke $S_{Blob,k} = \frac{1}{K}\sum_h S_{Blob}(i, j, \tilde{x}_h)$ durch lineare Interpolation zwischen den Schranken $\kappa_{Blob,\min}$ und $\kappa_{Blob,\max}$:

$$c_k = \Lambda_{high}(S_{Blob,k}, \kappa_{Blob,\min}, \kappa_{Blob,\max}).$$

Gilt $c_k > 0$ wird der fusionierte Blob als detektiertes Merkmal akzeptiert und der Einfluss der beteiligten Blobs aus den Einzelkanälen aus dem Interessantheitsbild entfernt.

5.4 Beschreibung punktförmiger Merkmale

Die detektierten Merkmale $\mathcal{M}$ werden an ihrem Ort und in ihrer charakteristischen Skala durch Helligkeit und Farbigkeit in der lokalen Umgebung beschrieben. Durch die Extraktion des Merkmalsdeskriptors in der charakteristischen Skala können die Merkmale skaleninvariant beschrieben werden. Implizit ist der Deskriptor auch blickwinkelinvariant, da sich bei Blickwinkeländerung die Skala des Merkmals entsprechend ändert.

Den Deskriptor d am Ort p und in Skala t bestimmen wir durch subpixel-genaue Berechnung der Helligkeits- und Farbwerte in p und t und anschließende Skalierung. Subpixelgenaue Helligkeits- und Farbwerte erhalten wir durch Taylorentwicklung bis zur 2. Ordnung um p auf der Skala t. Die benötigten Ableitungen erster und zweiter Ordnung approximieren wir durch Bildung entsprechender Differenzenquotienten.

Seien i und j derart gewählt, dass $t_{i,j} = t$, und sei $x := [p/h(i)]$. Die Approximation des Werts $K_{i,j}(p/h(i))$ in einem Kanal $K \in \{Y, U^+, U^-, V^+, V^-\}$ ist gegeben als

$$\begin{aligned}
\tilde{K}_{i,j}(p/h(i)) &\approx K_{i,j}(x) + dK_{i,j}(x)dx + \frac{1}{2}d^2K_{i,j}(x)dx^2, \text{ mit} \\
dx &= p/h(i) - x, \\
dK_{i,j} &= \frac{1}{2}\left(K_{i,j}(x+1) - K_{i,j}(x-1)\right), \text{ und} \\
d^2K_{i,j} &= \left(K_{i,j}(x+1) - 2K_{i,j}(x) + K_{i,j}(x-1)\right)
\end{aligned}$$

Der Deskriptor $d(p, t_{i,j})$ an Stelle p und Skala $t_{i,j}$ setzt sich aus skalierten Helligkeits- und

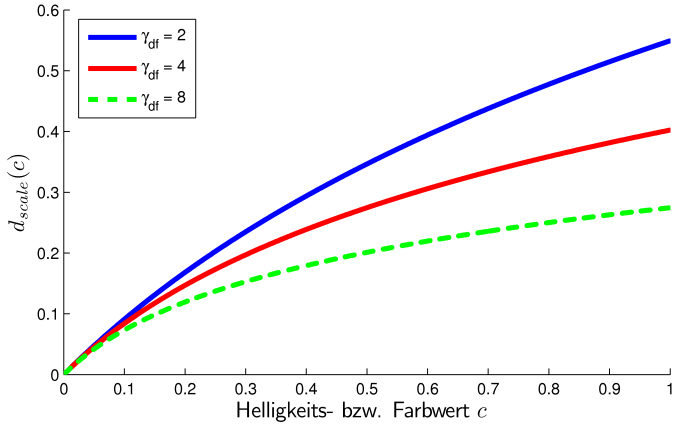

Abbildung 5.4: Skalierungsfunktion von Helligkeits- und Farbwerten zu Deskriptorwerten für $\gamma_{df} \in \{2, 4, 8\}$.

Farbwerten zusammen:

$$d(p, t_{i,j}) = \begin{pmatrix} d_{scale}\left(\tilde{Y}_{i,j}(p/h(i))\right) \\ d_{scale}\left(\tilde{U}^{+}_{i,j}(p/h(i))\right) \\ d_{scale}\left(\tilde{U}^{-}_{i,j}(p/h(i))\right) \\ d_{scale}\left(\tilde{V}^{+}_{i,j}(p/h(i))\right) \\ d_{scale}\left(\tilde{V}^{-}_{i,j}(p/h(i))\right) \end{pmatrix}$$

mit der Skalierungsfunktion

$$d_{scale}(c) := \frac{1}{\gamma_{df}} \log\left(\gamma_{df} c + 1\right).$$

Abb. 5.4 illustriert die Skalierungsfunktion für ausgewählte Parameter γ_{df}. Durch die Skalierung der Helligkeits- und Farbwerte wird erreicht, dass Abweichungen in niederen Werten größere Abstände in der skalierten Darstellung erzeugen als Änderungen in hohen Werten. Anschaulich sind nach der Skalierung intensive Werte eines Kanals ähnlicher als schwache Werte. Die Skalierungsfunktion besitzt zudem die Eigenschaft $\frac{\partial d_{scale}}{\partial c}(0) = 1$ für alle γ_{df}, d.h. für Werte nahe $c = 0$ bleibt die Skalierung der Helligkeits- und Farbwerte erhalten.

5.4.1 Kantenbeschreibung

Kanten werden durch ihre Seiten beschrieben, zwischen denen sie eine Grenze darstellen. Die detektierte Skala t_{m_k} einer Kante m_k im Ort p_{m_k} entspricht der minimalen Ausdehnung auf beiden Seiten bis zur nächsten Kante, insofern die Kante nicht in $t_{Edge,end}$ detektiert wurde und eine höhere charakteristische Skala besitzt. Um die Seiten einer Kante zu beschreiben, wählen wir die Orte $p_{m_k} \pm \sqrt{t_{m_k}}$. Damit die Beschreibung einer Seite nur zu verschwindendem Anteil Werte der gegenüberliegenden Seite und außerhalb der detektierten Ausdehnung des Merkmals enthält, werden Helligkeits- und Farbwerte

auf der Skala $\frac{1}{16}t_{m_k}$ extrahiert. Werte an der Stelle p_{m_k} tragen dadurch mit dem Gewicht $e^{(-8)} \approx 3.3 \cdot 10^{-4}$ zum Deskriptorwert bei. Für $t_{i,j} = t_{m_k}$ gilt $t_{i-2,j} = \frac{1}{16}t_{m_k}$, sodass die Werte in der Pyramide für $i > 2$ zur Verfügung stehen. Der Deskriptor eines Kantenmerkmals setzt sich aus der Beschreibung der linken und rechten Seite der Kante zusammen:

$$d_{m_k} = \left(d\left(p_{m_k} - \sqrt{t_{m_k}}, \frac{1}{16}t_{m_k}\right), d\left(p_{m_k} + \sqrt{t_{m_k}}, \frac{1}{16}t_{m_k}\right)\right).$$

5.4.2 Blobbeschreibung

Ein Blobmerkmal m_k wird direkt im detektierten Ort p_{m_k} beschrieben. Analog zur Kantenbeschreibung wird der Deskriptor in der Skala $\frac{1}{16}t_{m_k}$ extrahiert, da die Ausdehnung des Blobs von p_{m_k} bis zum nächsten Kontrast in der Skala maximal ca. $\sqrt{t_{m_k}}$ beträgt. Der Deskriptor des Merkmals lautet folglich

$$d_{m_k} = d\left(p_{m_k}, \frac{1}{16}t_{m_k}\right).$$

5.5 Verfolgung von Merkmalen in Bildsequenzen

Als Hinweis für die Datenassoziation im SLAM-Verfahren bestimmen wir eine Zuordnung von Merkmalen in zeitlich aufeinanderfolgenden Bildern, $\mathcal{Z}_{t,t+1} \subseteq \mathcal{M}_t \times \mathcal{M}_{t+1} \times (0,1]$. Das Verfahren berechnet zwischen Merkmalen m, m' desselben Typs ein Kompatibilitätsmass $comp_{match}(m,m')$ basierend auf dem Ortsabstand im Bild $\Delta p(m,m') := p_m - p_{m'}$ und der Differenz der Deskriptoren $\Delta d(m,m') := d_m - d_{m'}$:

$$comp_{match}(m,m') := -(2-c_m)(2-c_{m'})\sqrt{\frac{1}{1+\dim(d_m)}}\left\|\left(\Delta p(m,m')^T, \Delta d(m,m')^T\right)^T\right\|$$

Das Kompatibilitätsmass ist die mittlere quadratische Abweichung der Merkmale in Ort und Deskriptor und wird mit den Detektionssicherheiten c_m und $c_{m'}$ der Merkmale gewichtet, damit Zuordnungen von sicher detektierten Merkmalen bevorzugt werden. Eine Merkmalszuordnung ist inkompatibel, falls dieses Kompatibilitätsmass oder die Abstände in Ort oder Deskriptor überhalb von Schwellwerten liegen.

Für alle Merkmale $m_{t,k} \in \mathcal{M}_t, k \in \{1,\ldots,K_{M_t}\}$ wird die Kompatibilität zu den Merkmalen $m_{t+1,h} \in \mathcal{M}_{t+1}, h \in \{1,\ldots,K_{M_{t+1}}\}$ bestimmt. Es werden diejenigen Merkmalspaare $(m_{t,k}, m_{t+1,h})$ zugeordnet, die das Kompatibilitätsmaß maximieren. Ist das Merkmal $m_{t+1,h}$ bereits zu $m_{t,k'}$ zugeordnet, wird diese Zuordnung aufgelöst und ersetzt, falls die aktuelle Zuordnung zu $m_{t,k}$ eine bessere Kompatibilität besitzt. In diesem Fall wird erneut eine Zuordnung für das Merkmal $m_{t,k'}$ bestimmt.

Wurde eine Merkmalszuordnung $(m_{t,k}, m_{t+1,h})$ gefunden, wird die Sicherheit $c_{match,comp}(k,h)$ in dieser Zuordnung aus der Kompatibilität durch lineare Interpolation zwischen zwei Schranken bestimmt. Existiert eine zweitbeste Zuordnung, die eine ähnliche Kompatibilität wie die beste Zuordnung besitzt, kann eine eindeutige Zuordnung aufgrund von Unsicherheiten nicht hergestellt werden. Daher wird die Kompatibilität der besten Zuordnung mit der Kompatibilität der zweitbesten Zuordnung $(m_{t,k}, m_{t+1,h'})$ verglichen. Die Sicherheit $c_{match,2nd}(k,h)$ wird aus der Differenz von bester zu zweitbester Kompatibilität ebenfalls durch lineare Interpolation zwischen zwei Schranken berechnet.

Abbildung 5.5: Beispiel für die Merkmalsverfolgung. Detektierte Kanten- und Blob-Merkmale (Kreuze bzw. Kreise) im letzten Zeitschritt (oben) werden zu Merkmalen im aktuellen Zeitschritt (unten) zugeordnet.

Insgesamt erhalten wir die Zuordnungssicherheit $c_{match}(k,h)$ aus dem Minimum der beiden Sicherheiten $c_{match,comp}(k,h)$ und $c_{match,2nd}(k,h)$. Falls $c_{match}(k,h) > 0$, ist die Zuordnung $(m_{t,k}, m_{t+1,h}, c_{match}(k,h))$ in $\mathcal{Z}_{t,t+1}$ enthalten. Zuordnungen mit Sicherheit $c_{match}(k,h) = 0$ werden verworfen.

Unter der Annahme, dass lokal zusammenhängende Bildbereiche im Bild t auf wiederum lokal zusammenhängende Bildbereiche im Bild $t+1$ abgebildet werden, bestimmen wir aus der Merkmalszuordnung einen lokalen Versatz für die Merkmale im Ausgangsbild t. Wurde das Merkmal $m \in \mathcal{M}_t$ zu $m' \in \mathcal{M}_{t+1}$ zugeordnet, berechnet sich der individuelle lokale Versatz δp des Merkmals m als $\delta p = p_{m'} - p_m$. Für jedes Merkmal $m \in \mathcal{M}_t$ akkumulieren wir einen lokalen Versatz Δp aus Einflüssen der zugeordneten Merkmale $\check{m} \in \mathcal{M}_t^{\mathcal{Z}} := \{m \in \mathcal{M}_t | \exists m' \in \mathcal{M}_{t+1} : \exists c \in (0,1] : (m, m', c) \in \mathcal{Z}_{t,t+1}\}$ in Abhängigkeit von der Distanz des Merkmals m zu $\check{m}$:

$$\Delta p = \frac{1}{\sum_{\check{m} \in \mathcal{M}_t^{\mathcal{Z}}} w\left(p_m, p_{\check{m}}\right)} \sum_{\check{m} \in \mathcal{M}_t^{\mathcal{Z}}} w\left(p_m, p_{\check{m}}\right) \delta p, \text{ mit}$$

$$w\left(p_m, p_{\check{m}}\right) := \exp\left(-\frac{1}{2} \frac{\left(p_m - p_{\check{m}}\right)^2}{\sigma_{shift}^2}\right)$$

und der Standardabweichung σ_{shift} des lokalen Einflussbereichs.

Mit Hilfe dieses akkumulierten lokalen Versatzes kann die Merkmalszuordnung iterativ verbessert werden, indem die Orte der Merkmale in $\mathcal{M}_t$ gemäß ihres Versatzes in der nächsten Iteration verschoben werden. Nimmt man an, dass sich die Geschwindigkeit zusammenhängender Bildbereiche nur geringfügig zwischen zwei Bildern ändert, kann der lokale Versatz im nächsten Zeitschritt zur Initialisierung des Verfahrens genutzt werden. Bei einer ausreichend hohen Bildrate ist diese Annahme gerechtfertigt. Abb. 5.5 zeigt ein Ergebnis der Merkmalszuordnung in aufeinanderfolgenden Beispielbildern.

6 Simultanes Lokalisieren und Kartieren mit visuellen Landmarken

Das folgende Kapitel beschäftigt sich mit der simultanen Lokalisierung und Kartierung mit Hilfe von visuellen Landmarken. Wir fassen die detektierten Kanten- und Blobmerkmale als Observationen von Landmarken auf. In jedem Zeitschritt t werden daher Merkmale $\mathcal{M}_t$ mit Landmarken anhand des Deskriptors und des Orts im Bild assoziiert. Auf diese Weise stehen für assoziierte Landmarken Winkelobservationen zur Verfügung, mit denen die kartesischen Orte der Landmarken innerhalb der Karte durch Bewegungsparallaxe rekursiv geschätzt werden. Dazu ist es erforderlich, eine konsistente Schätzung der Trajektorie des Roboters aufrechtzuerhalten. Zur simultanen Schätzung von Trajektorie und Karte wird ein FastSLAM 2.0 Verfahren verwendet.

Zunächst wird das verwendete Bewegungsmodell des Roboters beschrieben. Anschließend wird die Repräsentation von Landmarken und das Landmarkenobservationsmodell bei reinen Winkelmessungen erläutert. Insbesondere gehen wir auf die besonderen Eigenschaften der Parametrisierung der Landmarkenpositionsschätzung ein. Um Landmarken mit Merkmalen zu assoziieren wird ein Verfahren vorgestellt, das Assoziation durch Merkmalsverfolgung in Bildsequenzen und modellgetriebene Assoziation verknüpft. Eine wichtige Frage für die Datenassoziation ist die mögliche Sichtbarkeit von Landmarken in der Pose des Roboters. Können Merkmale nicht mit Landmarken assoziiert werden, müssen neue Landmarken geeignet in die Karte eingefügt werden. Ebenso entfernen wir Landmarken aus der Karte, die unzureichend kartiert werden konnten oder von Fehldetektionen herrühren. Die erwartete Sichtbarkeit von Landmarken ist hier ein wesentliches Konzept.

Es wird ein FastSLAM 2.0 Verfahren verwendet, da die Observation von Winkeln zu Landmarken deutlich geringerem Rauschen unterliegt als die Bewegung des Roboters. Zudem bewirken Orientierungsfehler in der Posenschätzung einen Winkelfehler in allen Landmarkenobservationen, sodass Partikel mit geringem Orientierungsfehler überkonfident bewertet werden. Durch die Posenkorrektur wird dieser Effekt reduziert. Allerdings ergeben sich neue Schwierigkeiten, denn das Verfahren ist erheblich anfälliger für falsche Datenassoziationen, die zu falschen Korrekturen der Posenschätzung führen. Daher wird die Posenkorrektur mittels RANSAC [37] (aus dem engl., Random Sample Consensus) robustiert.

6.1 Bewegungsmodell des Roboters

Der Roboter verfügt über einen omnidirektionalen Antrieb, der durch Kontrolleingaben in Form von egozentrischen Geschwindigkeiten $u_t = (v_x, v_y, w)$ in Vorwärts- und Seitwärtsrichtung und um die vertikale Achse gesteuert wird. Aufgrund von Ungenauigkeiten in der Ausführung dieser Kontrolleingaben und unmodellierten Begebenheiten des Bodens

unterliegt die Bewegungsausführung Rauschen, das wir normalverteilt modellieren:

$$\hat{v}_t = (\hat{v}_x, \hat{v}_y, \hat{w})^T = u_t + \epsilon_t, \epsilon_t \sim \mathcal{N}(0, R_t).$$

Die Kovarianz R_t ist isotrop und enthält in der Diagonalen Varianzen $\sigma_x^2, \sigma_y^2, \sigma_w^2$ für jede Geschwindigkeitskomponente, die vom Betrag der Geschwindigkeitskomponenten abhängen:

$$\begin{aligned}
\sigma_x &= \alpha_{x,1}|v_x| + \alpha_{x,2}|v_y| + \alpha_{x,3}|w| \\
\sigma_y &= \alpha_{y,1}|v_x| + \alpha_{y,2}|v_y| + \alpha_{y,3}|w| \\
\sigma_w &= \alpha_{w,1}|v_x| + \alpha_{w,2}|v_y| + \alpha_{w,3}|w|
\end{aligned}$$

Der Roboter bewegt sich für $w \neq 0$ auf einer Kreisbahn mit dem Radius $r = \frac{\|(v_x, v_y)^T\|}{w}$. Während Länge und Radius dieser Kreisbahn durch das Rauschen beeinflusst werden, ist die Endorientierung durch die Modellierung der perfekten Kreisbewegung festgelegt [25]. Daher modellieren wir im Zustandsübergangsmodell zusätzliches Rauschen in der Endorientierung des Roboters als Winkelgeschwindigkeit $\hat{\gamma} \sim \mathcal{N}(0; \sigma_\gamma^2)$ mit $\sigma_\gamma = \alpha_{\gamma,1}|v_x| + \alpha_{\gamma,2}|v_y| + \alpha_{\gamma,3}|w|$. Beschreibt $s_{t-1} = (x_{t-1}, y_{t-1}, \theta_{t-1})$ die Pose des Roboters zum Zeitpunkt $t-1$, ergibt sich mit der tatsächlichen Geschwindigkeit v_t und der vergangenen Zeit Δt zwischen $t-1$ und t die neue Pose aus dem Zustandsübergangsmodell

$$g(s_{t-1}, v_t) = \begin{cases} g_{w=0}(s_{t-1}, v_t) & \text{, falls } \hat{w} = 0 \\ g_{w\neq 0}(s_{t-1}, v_t) & \text{, falls } \hat{w} \neq 0 \end{cases}$$

mit

$$g_{w=0}(s_{t-1}, v_t) = \begin{pmatrix} x_{t-1} \\ y_{t-1} \\ \theta_{t-1} \end{pmatrix} + \begin{pmatrix} R(\theta_t)\Delta t & 0 & 0 \\ & 0 & 0 \\ 0 \quad 0 & \Delta t & \Delta t \end{pmatrix} \begin{pmatrix} \hat{v}_x \\ \hat{v}_y \\ \hat{w} \\ \hat{\gamma} \end{pmatrix}$$

und

$$g_{w\neq 0}(s_{t-1}, v_t) = \begin{pmatrix} x_{t-1} \\ y_{t-1} \\ \theta_{t-1} \end{pmatrix} + \begin{pmatrix} \frac{1}{\hat{w}}\left(I_2 + R(\hat{w}\Delta t)\right) R(\theta_t) R\left(\frac{\pi}{2}\right) & 0 & 0 \\ & 0 & 0 \\ 0 \qquad 0 & \Delta t & \Delta t \end{pmatrix} \begin{pmatrix} \hat{v}_x \\ \hat{v}_y \\ \hat{w} \\ \hat{\gamma} \end{pmatrix}$$

6.2 Beschreibung und Observation von Landmarken

Eine Landmarke L_j repräsentiert eine Kante oder einen Blob an einer kartesischen Position l_j in der Karte. Die Landmarke wird als Bildmerkmal observiert, sodass lediglich Winkel zur Landmarke und ihr Deskriptor beobachtet werden können. Die Zustandsschätzung $\lambda_{j,t} = (p_{j,t}, d_{j,t}, \sigma_{d,j,t}, \tau_{j,t}, \phi_{det,j,t}, \Delta\phi_{det,j,t}, c_{obs,j,t}, n_{det,j,t}, n_{misdet,j,t})$ einer Landmarke zum Zeitpunkt t umfasst die Positionsschätzung $p_{j,t}$, die Schätzung des eventuell zweiseitigen Deskriptors $d_{j,t}$ mit Standardabweichungen $\sigma_{d,j,t}$ für jede Komponente, den Typ $\tau_{j,t} \in \{Kante, Blob\}$, das detektierte Sichtbarkeitswinkelintervall $\phi_{det,j,t}$ bis $\phi_{det,j,t} + \Delta\phi_{det,j,t}$ im Standpunkt der Landmarke, die Sichtungssicherheit $c_{obs,j,t}$ und die Zahl der Detektionen $n_{det,j,t}$ bzw. Fehldetektionen $n_{misdet,j,t}$. Die Schätzung der Karte zum Zeitpunkt t bezeichnen wir als $\mathcal{L}_t := \{\lambda_{j,t}\}_{j=1}^{N_t}$. Die Karte ist partikelspezifisch. Aus

Gründen der Übersichtlichkeit wurde die Notation $^{[i]}$ für $\mathcal{L}_t$, $\lambda_{j,t}$ und die einzelnen Komponenten weggelassen.

Das observierte Bildmerkmal $m \in \mathcal{M}_t$ einer Landmarke l_j wird im Bild mit Subpixel-Genauigkeit im Ort p_m detektiert, der in der Pose s_t des Roboters einem Sichtwinkel zur Landmarke entspricht. Aufgrund von Ungenauigkeiten in der Bildaufnahme und der Merkmalsdetektion unterliegt der detektierte Ort Rauschen, welches wir normalverteilt modellieren. Wir verwenden das Kamera- und Linsenverzerrungsmodell aus Abschnitt 4.3 als invertierbare Abbildung von unverzerrten metrischen Bildkoordinaten x_u in pixelwertige Bildkoordinaten x_p.

Landmarkenpositionsschätzungen werden sowohl in kartesischen Koordinaten als auch in inverser Tiefe parametrisiert. Die Parametrisierung in Sichtwinkel und inverser Tiefe entlang der Sichtlinie der ersten Sichtung ermöglicht eine unverzögerte Initialisierung der Landmarke. Das bedeutet, dass Landmarken bereits bei der ersten Sichtung ohne spezielle Behandlung in die Karte aufgenommen werden, insbesondere vor einer sicheren Schätzung der Tiefe.

Die verzerrte Bildkoordinate, in der die Landmarke in der Pose $s_t = (x_t, y_t, \theta_t)^T$ beobachtet wird, ist durch das Observationsmodell h bestimmt:

$$z_t = h(s_t, l_j) + \delta_t = \mathit{distort}(\mathit{project1D}(\mathit{localtransform}(l_j, s_t))) + \delta_t$$

mit additivem normalverteiltem Rauschen $\delta_t \sim \mathcal{N}(0, Q_t)$.

6.2.1 Kartesische Parametrisierung

Eine Landmarkenpositionsschätzung $p_{j,t} = (\mu_{j,t}, \Sigma_{j,t})$ in kartesischer Parametrisierung $(x, y)^T$ besteht aus einer normalverteilten Schätzung der globalen kartesischen Landmarkenposition mit Mittelwert $\mu_{j,t} = (\hat{x}_{j,t}, \hat{y}_{j,t})^T$ und Kovarianz $\Sigma_{j,t} \in \mathbb{R}^{2\times 2}$.

6.2.2 Inverse Tiefenparametrisierung

Eine weitere Art der Parametrisierung der Landmarkenpositionsschätzung besteht in der normalverteilten Schätzung von Sichtwinkel θ und inverser Tiefe ρ entlang der Sichtlinie der ersten Sichtung der Landmarke [13]. Da im FastSLAM-Verfahren angenommen wird, dass die Partikelpose nach der Ziehung von der Sampling-Verteilung bekannt ist, modellieren wir für den ersten Sichtungsort p_o keine Unsicherheit. Die Positionsschätzung $p_{j,t} = (p_{o,j}, \mu_{j,t}, \Sigma_{j,t})$ setzt sich daher aus dem bekannten ersten Sichtungsort $p_{o,j} = (x_{o,j}, y_{o,j})^T$, dem Mittelwert des globalen Sichtwinkels und der inversen Tiefe $\mu_{j,t} = (\hat{\theta}_{j,t}, \hat{\rho}_{j,t})^T$ und deren Kovarianz $\Sigma_{j,t} \in \mathbb{R}^{2\times 2}$ zusammen.

Zur Berechnung der kartesischen Position l_j der Landmarke aus den Parametern p_o, θ und ρ der inversen Tiefenparametrisierung definieren wir die Funktion

$$\mathit{endpoint}(p_o, (\theta, \rho)^T) := p_o + \frac{1}{\rho}(\mathit{cos}(\theta), \mathit{sin}(\theta))^T.$$

Eine Besonderheit für das Observationsmodell sind Landmarken im Unendlichen, d.h. $\rho \approx 0$, die im Winkel $\theta - \theta_t$ bzw. in der verzerrten Bildkoordinate $z_t = \mathit{distort}(\tan(\theta - \theta_t)) + \delta_t$ beobachtet werden, falls $-\frac{\pi}{2} < \theta - \theta_t < \frac{\pi}{2}$.

6.2.3 Eigenschaften der Parametrisierungsformen

Die Parametrisierung in inverser Tiefe bietet grosse Vorteile für die rekursive Schätzung der Landmarkenposition. Zum einen ermöglicht sie die unverzögerte Initialisierung von Landmarken. Das bedeutet, dass die Landmarke bereits bei ihrer ersten Sichtung mit einer normalverteilten Schätzung in inverser Tiefe initialisiert werden kann, da das Observationsmodell nahezu linear in der inversen Tiefenkoordinate ist [13]. Es ist also kein spezieller Initialisierungsprozess erforderlich, um zu einer initialen Positionsschätzung einer Landmarke zu gelangen, sodass das kartesische Observationsmodell für die weitere Schätzung mit dem EKF-Verfahren hinreichend linear in den Positionsparametern ist wie in [11, 38, 39]. Insbesondere dienen Landmarken dadurch bereits bei ihrer zweiten Sichtung als Orientierungsindikator. Eine weitere besondere Eigenschaft ist die mögliche Abdeckung des gesamten Tiefenspektrums von nahen Tiefen bis hin zur unendlichen Tiefe. In Abb. 6.1 wird in einem Beispiel illustriert, wie sich die Unsicherheit in der Positionsschätzung für die jeweilige Parametrisierungsform auf die Unsicherheit im Observationsmodell auswirkt. In der gegebenen Konfiguration ist das Observationsmodell in der kartesischen Parametrisierung stark nichtlinear, sodass die Observationen der unsicheren Landmarkenposition nicht normalverteilt modelliert werden können.

Seien $s = (x, y, \theta)^T$ und $s' = (x', y', \theta')^T$ Roboterposen und sei $\hat{p}_l = (\hat{x}_l, \hat{y}_l)^T$ die mittlere Position einer Landmarke. Die Schätzung der Landmarkenposition sei normalverteilt sowohl in Tiefen- als auch in inverser Tiefenform im Koordinatensystem der ersten Roboterpose s gegeben, wobei die Winkelunsicherheit vernachlässigt wird. Die mittleren Tiefen $\hat{d}, \hat{d}'$ bzw. inversen Tiefen $\hat{\rho} = \frac{1}{\hat{d}}, \hat{\rho}' = \frac{1}{\hat{d}'}$ von den beiden Roboterpositionen zur Landmarkenposition ergeben sich aus

$$\hat{d} := \left\|\hat{p}_l - (x, y)^T\right\| \text{ bzw. } \hat{d}' := \left\|\hat{p}_l - (x', y')^T\right\|$$

Für die Tiefenparametrisierung erhält man die normalverteilte Schätzung von p_l parametrisiert in der mittleren Distanz $\hat{d}$ zwischen s und p und deren Varianz σ_d^2, d.h.

$$p_l = (x, y)^T + d\left(\frac{\hat{p}_l - (x, y)^T}{\|\hat{p}_l - (x, y)^T\|}\right)$$

mit $d \sim \mathcal{N}(\hat{d}, \sigma_d^2)$. Die Schätzung in inverser Tiefe wird analog normalverteilt mit mittlerer inverser Tiefe $\hat{\rho}$ und Varianz σ_ρ^2 modelliert:

$$p_l = (x, y)^T + \frac{1}{\rho}\left(\frac{\hat{p}_l - (x, y)^T}{\|\hat{p}_l - (x, y)^T\|}\right)$$

mit $\rho \sim \mathcal{N}(\hat{\rho}, \sigma_\rho^2)$. Desweiteren bezeichnet der Parallaxwinkel α den mittleren Winkel zwischen den Sichtstrahlen von den Roboterpositionen zur Landmarkenposition.

Civera et al. leiten in [40] Kriterien für die Linearität der Observationsmodelle in der zweiten Roboterposition unter Vernachlässigung von radialer Linsenverzerrung her. Sie fordern die Linearität des Observationsmodells in einer $2\sigma_x$-Umgebung um den normalverteilten Parameter x mit Mittelwert $\hat{x}$, und approximieren hierfür die erste Ableitung des Observationsmodells durch Taylorexpansion:

$$\frac{\partial h}{\partial x}(\hat{x} + \Delta x) \approx \frac{\partial h}{\partial x}(\hat{x}) + \frac{\partial^2 h}{\partial x^2}(\hat{x})\Delta x$$

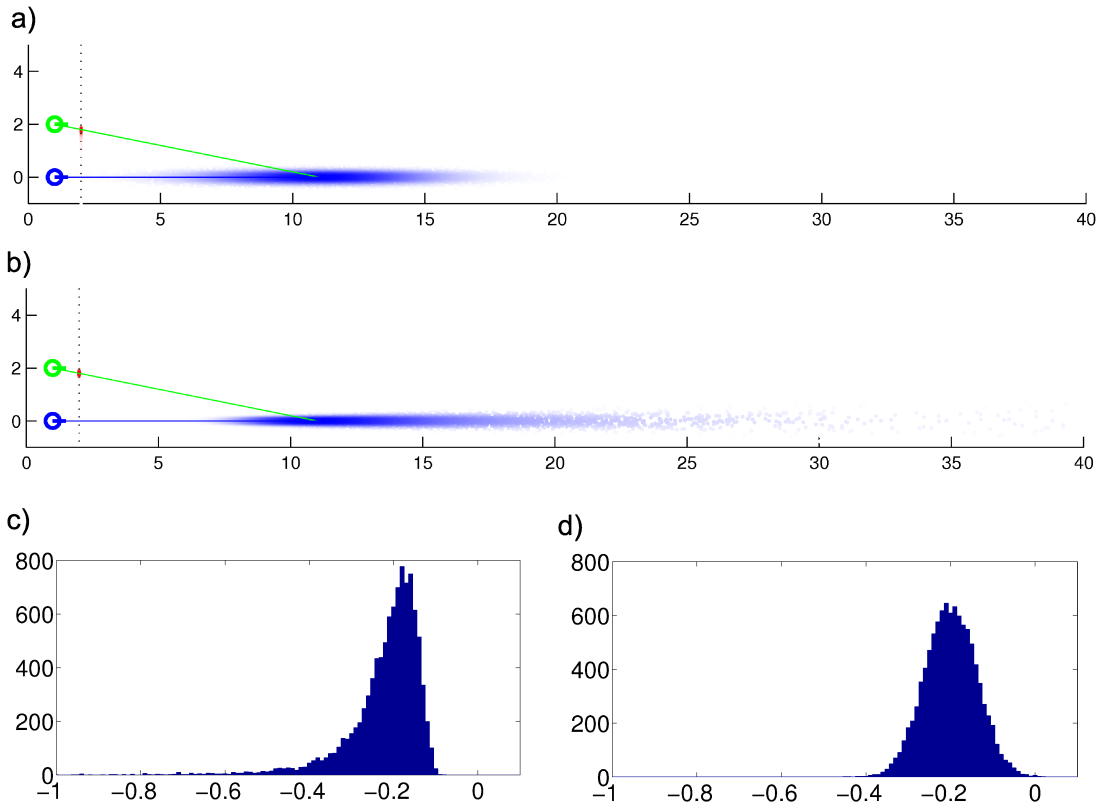

Abbildung 6.1: Beispiel für die Observation einer unsicheren Landmarke, die mit hoher Unsicherheit in der Tiefe kartesisch (a, c) und in inverser Tiefe (b, d) parametrisiert ist. Die Positionsschätzungen besitzen denselben Mittelwert und vergleichbare Kovarianz. In a) und b) wird die Observation der Landmarke in kartesischer bzw. in inverser Tiefenparametrisierung dargestellt. Die Schätzung wird in der blauen Pose initialisert und in der grünen Pose observiert. Die gestrichelte Linie skizziert die Bildebene. Das Histogramm in c) bzw. d) visualisiert die Verteilung von observierten Bildkoordinaten von 10000 Stichproben der Landmarkenposition in kartesischer bzw. inverser Tiefenparametrisierung. Ein Kolmogorov-Smirnoff-Test zum Signifikanzniveau 5% liefert für die Stichprobenmenge der Bildkoordinaten in der kartesischen Parametrisierung, dass die Hypothese einer Normalverteilung der Stichproben verworfen werden kann. Für die inverse Tiefenparametrisierung kann die Normalverteilung der Bildkoordinatenstichproben nicht zurückgewiesen werden. Das Beispiel zeigt, dass die normalverteilte Modellierung der Unsicherheit im Observationsmodell für die kartesische Parametrisierung bei hoher Unsicherheit in der Tiefe eine schlechte Näherung ist.

Die Ableitungen in $\hat{x}$ und $\hat{x} \pm 2\sigma_x$ werden mit dem dimensionslosen Linearitätsindex

$$L_x = \left| \frac{\frac{\partial^2 h}{\partial x^2}(\hat{x}) 2\sigma_x}{\frac{\partial h}{\partial x}(\hat{x})} \right|$$

verglichen. Ist das Observationsmodell in der $2\sigma_x$-Umgebung näherungsweise linear, gilt $L \approx 0$.

Für die beiden Parametrisierungsformen ergeben sich die Linearitätsindizes

$$\begin{aligned} L_d &= \frac{4\sigma_d}{\hat{d}'} \left|\cos(\alpha)\right| \text{ und} \\ L_\rho &= \frac{4\sigma_\rho}{\hat{\rho}} \left| 1 - \frac{\hat{d}}{\hat{d}'} \cos(\alpha) \right| \end{aligned} \tag{6.1}$$

Bei geringer Parallaxe, d.h. $\cos(\alpha) \approx 1$, und für $\frac{\hat{d}}{\hat{d}'} \approx 1$ ist das inverse Tiefenobservationsmodell näherungsweise linear in ρ. Insbesondere ist das auch der Fall, wenn die Unsicherheit groß ist ($\frac{4\sigma_\rho}{\hat{\rho}} >> 0$). Für zunehmende Parallaxwinkel sinkt die Unsicherheit σ_ρ, sodass trotz zunehmendem Term $\left|1 - \frac{\hat{d}}{\hat{d}'} \cos(\alpha)\right|$ die Linearität näherungsweise gegeben ist. Dahingegen gilt $L_d \approx 0$ für $\cos(\alpha) \approx 1$ nur, falls $\hat{d}' >> \sigma_d$. Bei geringer Parallaxe ist das Tiefenobservationsmodell also nur dann annähernd linear, falls die relative Unsicherheit in der Tiefe gering ist.

6.3 Simultane Schätzung von Trajektorie und Karte

In seiner ursprünglichen Formulierung wird im FastSLAM 2.0 Verfahren in jedem Zeitschritt t jeweils nur eine Observation z_t nach einer Kontrolleingabe u_t verarbeitet. Im vorliegenden Fall stehen aber in jedem Zeitschritt mehrere Observationen $z_t = \{z_{t,k}\}_{k=1}^{K_t}$ von paarweise verschiedenen Landmarken zur Verfügung. Die Sampling-Verteilung in Gl. (3.3) lässt sich in diesem Fall unter der Annahme der stochastischen Unabhängigkeit der einzelnen Observationen zu

$$\begin{aligned} &p(s_t | s_{1:t-1}^{[i]}, u_{1:t}, z_{1:t}, c_{1:t}) = \\ &\qquad \eta^{[i]} p(s_t | s_{t-1}^{[i]}, u_t) \prod_{k=1}^{K_t} \int p(z_{t,k} | l_{c_{t,k}}, s_t, c_{t,k})\; p(l_{c_{t,k}} | s_{1:t-1}^{[i]}, z_{1:t-1}, c_{1:t-1})\; dl_{c_{t,k}} \end{aligned}$$

umformen [4]. Mit der Notation aus Abschnitt 3.6.2 bezeichnen wir die Erwartung für die k-te Observation in der mittleren Pose mit $\hat{z}_{t,k}^{[i]} := h(\mu_{c_{t,k},t-1}^{[i]}, \hat{s}_t^{[i]})$ und die ersten Ableitungen des Observationsmodells bezüglich der Landmarken- bzw. Posenkoordinaten ausgewertet in mittlerer Landmarkenposition und Pose als

$$\begin{aligned} H_{l,k} &:= \nabla_{l_{c_{t,k}}} h(l_{c_{t,k}}, s_t)\Big|_{\mu_{c_{t,k},t-1}^{[i]}, \hat{s}_t^{[i]}} \text{ bzw.} \\ H_{s,k} &:= \nabla_{s_t} h(l_{c_{t,k}}, s_t)\Big|_{\mu_{c_{t,k},t-1}^{[i]}, \hat{s}_t^{[i]}} \end{aligned}$$

Für die normalverteilte Sampling-Verteilung (Gl.(3.3)) ergibt sich durch Anwendung des Faltungstheorems [4]:

$$p(s_t|s_{1:t-1}^{[i]}, u_{1:t}, z_{1:t}, c_{1:t}) \approx \eta^{[i]}\mathcal{N}(s_t; \mu_{s_t}, \Sigma_{s_t}), \text{ mit}$$

$$\Sigma_{s_t} = \left(\left(R_t^{[i]}\right)^{-1} + \sum_{k=1}^{K_t} H_{s,k}^T (Q_{t,k} + H_{l,k}\Sigma_{c_{t,k},t-1}^{[i]} H_{l,k}^T)^{-1} H_{s,k}\right)^{-1},$$

$$\mu_{s_t} = \hat{s}_t^{[i]} + \Sigma_{s_t} \sum_{k=1}^{K_t} H_{s,k}^T (Q_{t,k} + H_{l,k}\Sigma_{c_{t,k},t-1}^{[i]} H_{l,k}^T)^{-1} (z_{t,k} - \hat{z}_{t,k}^{[i]})$$

Die Berechnung von $(\mu_{s_t}, \Sigma_{s_t})$ kann rekursiv in Kalman-Form durchgeführt werden. Das Verfahren wird mit Mittelwert und Kovarianz des Zustandsübergangsmodells initialisiert, d.h.

$$\mu_{s_t,0} := \hat{s}_t^{[i]}, \text{ und}$$
$$\Sigma_{s_t,0} := R_t^{[i]}.$$

Für alle $k \in \{1, \ldots, K_t\}$ wird die Posenschätzung $(\mu_{s_t,k-1}, \Sigma_{s_t,k-1})$ mit der Observation $z_{t,k}$ korrigiert:

$$\begin{aligned}
\check{z}_{t,k} &= h(\mu_{c_{t,k},t-1}^{[i]}, \mu_{s_t,k-1}) \\
Z_{t,k} &= H_{s,k}\Sigma_{s_t,k-1}H_{s,k}^T + H_{l,k}\Sigma_{c_{t,k},t-1}^{[i]}H_{l,k}^T + Q_{t,k} \\
K_{t,k} &= \Sigma_{s_t,k-1}H_{s,k}^T Z_{t,k}^{-1} \\
\mu_{s_t,k} &= \mu_{s_t,k-1} + K_{t,k}\left(z_{t,k} - \check{z}_{t,k}\right) \\
\Sigma_{s_t,k} &= (I - K_{t,k}H_{s,k})\Sigma_{s_t,k-1}
\end{aligned} \tag{6.2}$$

Die korrigierte Posenschätzung des i-ten Partikels ergibt sich damit als $\left(\mu_{s_t}^{[i]}, \Sigma_{s_t}^{[i]}\right) = (\mu_{s_t,K_t}, \Sigma_{s_t,K_t})$.

Um die Partikelgewichte analog zu Gl. (3.4) zu berechnen, kann die gemeinsame Verteilung über die Observationen im aktuellen Zeitschritt durch Bedingen der k-ten Observation auf die Observationen 1 bis $k-1$ faktorisiert werden:

$$\begin{aligned}
w_t^{[i]} &= w_{t-1}^{[i]}\ \eta\ p(z_t|s_{1:t-1}^{[i]}, z_{1:t-1}, u_{1:t}, c_{1:t}) \\
&= \eta \prod_{k=1}^{K_t} p(z_{t,k}|z_{t,1:k-1}, s_{1:t-1}^{[i]}, z_{1:t-1}, u_{1:t}, c_{1:t}) \\
&= w_{t-1}^{[i]}\ \eta \prod_{k=1}^{K_t} w_{t,k}^{[i]}
\end{aligned} \tag{6.3}$$

Eine observierte Landmarke erhält das Gewicht [4]

$$w_{t,k}^{[i]} = \int \underbrace{p(s_t|s_{1:t-1}^{[i]}, z_{t,1:k-1}, u_t, c_{t,1:k-1})}_{\mathcal{N}(s_t;\mu_{s_t,k-1},\Sigma_{s_t,k-1})} \int \underbrace{p(z_{t,k}|l_{c_{t,k}}, s_t, c_{t,k})}_{\mathcal{N}(z_{t,k};h(s_t,l_{c_{t,k}}),Q_{t,k})} \underbrace{p(l_{c_{t,k}}|s_{1:t-1}^{[i]}, z_{1:t-1}, u_{1:t-1}, c_{1:t-1})}_{\mathcal{N}(l_{c_{t,k}};\mu_{c_{t,k},t-1}^{[i]},\Sigma_{c_{t,k},t-1}^{[i]})} dl_{c_{t,k}} ds_t$$

welches die Observationswahrscheinlichkeit der k-ten Observation unter der Posenschätzung nach Integration der $(k-1)$-ten Observation, der Landmarkenpositionsschätzung und der Observationsunsicherheit darstellt. Durch erneute Anwendung des Faltungstheorems erhält man die Observationswahrscheinlichkeit in geschlossener Form:

$$w_{t,k}^{[i]} \approx \mathcal{N}(z_{t,k}; \check{z}_{t,k}, Z_{t,k}) \tag{6.4}$$

Die Landmarkenpositionsschätzungen werden wie gehabt anhand der gezogenen Pose $s_t^{[i]}$ ohne Unsicherheit aktualisiert.

6.4 Initiale Posenschätzung

Jedes Partikel trägt vor dem Zeitschritt t eine Hypothese für die letzte Pose $s_{t-1}^{[i]}$. Für die Datenassoziation im neuen Zeitschritt soll die Unsicherheit in der Partikelpose nach Integration der Kontrolleingabe u_t berücksichtigt werden. Außerdem wird zur Posenkorrektur eine normalverteilte Approximation der aktuellen Posenschätzung nach Ausführung der Kontrolleingabe u_t benötigt. Daher approximieren wir diese Posenschätzung durch Linearisierung des Zustandübergangsmodells in Pose $s_{t-1}^{[i]}$ des Partikels und der Kontrolleingabe u_t, und erhalten die Posenschätzung $\left(\hat{s}_t^{[i]}, R_t^{[i]}\right)$ durch Fehlerpropagation erster Ordnung:

$$\begin{aligned}
\hat{s}_t^{[i]} &= g(s_{t-1}^{[i]}, u_t) \\
R_t^{[i]} &= G_u \underbrace{\begin{pmatrix} \sigma_x^2 & 0 & 0 & 0 \\ 0 & \sigma_y^2 & 0 & 0 \\ 0 & 0 & \sigma_w^2 & 0 \\ 0 & 0 & 0 & \sigma_\gamma^2 \end{pmatrix}}_{=:V_t} G_u^T
\end{aligned}$$

mit $G_u := \nabla_u g(s,u)|_{s=s_{t-1}^{[i]}, u=u_t}$.

6.5 Assoziation von Landmarken mit Bildmerkmalen

Die Assoziation von Landmarken mit Bildmerkmalen desselben Typs wird für jedes Partikel individuell hergestellt. Wir bezeichnen die Menge der Assoziationen des i-ten Partikels als

$$\mathcal{C}_t^{[i]} := \{c_{t,k}^{[i]}\}_{k=1}^{K_t}.$$

Die Korrespondenz $c_{t,k}^{[i]}$ entspricht dem Index der Landmarke, die mit dem k-ten Merkmal assoziiert wurde. Die Teilmenge der assoziierten Merkmale wird mit Hilfe der Indexmenge $\mathcal{K}_{assoc,t}^{[i]} \subseteq \{1, \ldots, K_t\}$ definiert. Die Anzahl der assoziierten Merkmale kürzen wir mit $K_{assoc,t}^{[i]}$ ab.

Wir verwenden die Merkmalszuordnung zwischen zwei Bildern als Hinweis für die Datenassoziation, indem für zugeordnete Merkmale versucht wird, dieselbe Landmarke zu assoziieren. Kann die Assoziation für eine Landmarke auf diese Weise nicht sicher hergestellt werden, kann die Landmarke modellgetrieben mit Merkmalen assoziiert werden, die in

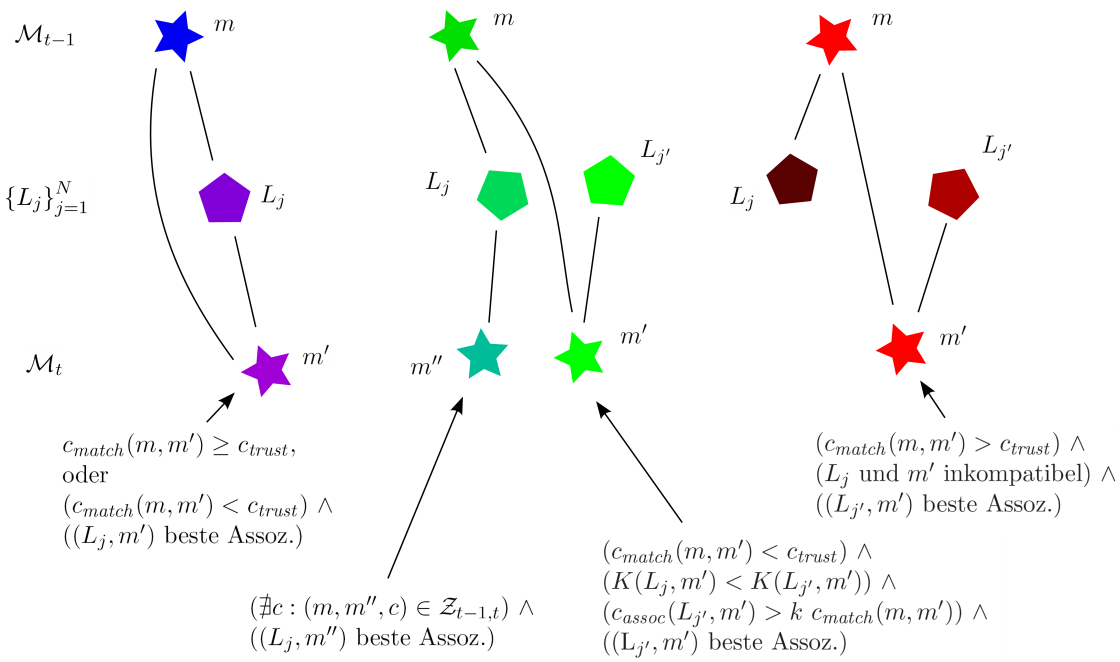

Abbildung 6.2: Exemplarische Fälle für die kombinierte Datenassoziation durch Merkmalsverfolgung und modellgetriebene Assoziation. Verbindungen zeigen Zuordnungen an.

Winkel und Deskriptor kompatibel sind. Abb. 6.2 illustriert Beispiele für Fälle, die während der Datenassoziation auftreten.

Die Kompatibilität eines Merkmals m zu einer Landmarke L_j bestimmen wir als Abweichung des Merkmals in Bildkoordinate und Deskriptor von der erwarteten Observation unter den aktuellen Posen- und Landmarkenschätzungen. Da jedes Partikel individuelle Posen- und Landmarkenschätzungen unterhält, muss die Datenassoziation für jedes Partikel individuell hergestellt werden.

Zum Zeitpunkt t enthält das i-te Partikel vor der Kartenaktualisierung eine normalverteilte Schätzung $(\mu_{j,t-1}^{[i]}, \Sigma_{j,t-1}^{[i]})$ der tatsächlichen Landmarkenposition l_j. Nach Integration der Kontrolleingabe u_t ist auch die Pose des i-ten Partikels mit Unsicherheit behaftet und ist durch die normalverteilte initiale Posenschätzung $\left(\hat{s}_t^{[i]}, R_t^{[i]}\right)$ gegeben. Die Landmarke wird in der verzerrten Bildkoordinate $z_t = p_m$ des Merkmals gemessen, die einem Observationswinkel entspricht. Für die Messung z_t nehmen wir nach dem Observationsmodell an, dass sie normalverteilt um die erwartete Messung $\hat{z}_t = h(s_t, l_j)$ mit Kovarianz Q_t streut. Die implizite Messfunktion $f(s_t, l_j, \hat{z}_t) = \hat{z}_t - h(s_t, l_j) = 0$ drückt die Forderung aus, dass erwartete und tatsächliche Messung übereinstimmen [30]. Da die tatsächlichen Werte nicht zur Verfügung stehen, wird die implizite Messfunktion um die aktuellen Schätzungen linearisiert:

$$f(s_t, l_j, \hat{z}_t) \approx f(\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}, z_t) + H_s(s_t - \hat{s}_t^{[i]}) + H_l(l_j - \mu_{j,t-1}^{[i]}) + H_z(\hat{z}_t - z_t)$$

mit den ersten Ableitungen

$$\begin{aligned}
H_s &:= \nabla_{s_t} f(s_t, l_j, \hat{z}_t)\big|_{\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}, z_t} &= \nabla_{s_t} h(s_t, l)\big|_{\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}} \\
H_l &:= \nabla_{l_j} f(s_t, l_j, \hat{z}_t)\big|_{\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}, z_t} &= \nabla_{l_j} h(s_t, l_j)\big|_{\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}} \\
H_z &:= \nabla_{\hat{z}_t} f(s_t, l_j, \hat{z}_t)\big|_{\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}, z_t} &= 1
\end{aligned}$$

Die Innovation $\Delta z_t = f(\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}, z_t)$ besitzt somit die Kovarianz $C_z = H_s R_t^{[i]} H_s^T + H_l \Sigma_{j,t-1}^{[i]} H_l^T + Q_t$. Die Kompatibilität von Landmarke und Merkmal wird durch den Innovationstest

$$D_z^2(L_j, m) = \Delta z_t^T C_z^{-1} \Delta z_t < \chi^2_{n_z,\alpha} \tag{6.5}$$

geprüft. Der Schwellwert $\chi^2_{n_z,\alpha}$ ist definiert als Wert der χ^2-Verteilung mit $n_z = \dim(f)$ Freiheitsgraden zum Konfidenzlevel α, mit dem die Fehlerrate des Tests eingestellt wird. Liegt die Mahalanobisdistanz unterhalb des Schwellwerts, wird Kompatibilität von L_j und m angenommen. Als Mass für die Kompatibilität verwenden wir $K_z(L_j, m) = -D_z^2(L_j, m)$.

In analoger Weise kann die Kompatibilität zweier Deskriptorobservationen $d \sim \mathcal{N}(\hat{d}, P)$ und $d' \sim \mathcal{N}(\hat{d}', P')$ bestimmt werden. In diesem Fall besitzt die Innovation $\Delta d = d - d'$ die Kovarianz $C_d = P + P'$, und der Innovationstest

$$D_d^2(L_j, m) = \Delta d^T C_d^{-1} \Delta d < \chi^2_{n_d,\alpha} \tag{6.6}$$

liefert die Kompatibilität $K_d(L_j, m) = -D_d^2(L_j, m)$ der Deskriptoren. Die Anzahl der Freiheitsgrade der χ^2-Verteilung beträgt $n_d = \dim(d) = \dim(d')$. Sind Merkmal und Landmarke vom Kantentyp, wird die Kompatibilität der beiden Deskriptorseiten separat berechnet und geprüft. Die Gesamtkompatibilität $K(L_j, m)$ in Bildkoordinatenmessung und Deskriptor ergibt sich als gewichtete Summe der Einzelkompatibilitäten, sodass ein ausgewogenes Verhältnis eingestellt werden kann.

6.5.1 Datenassoziation durch Merkmalsverfolgung

Wurde im vergangenen Zeitschritt für das i-te Partikel das Bildmerkmal $m \in \mathcal{M}_{t-1}$ mit einer Landmarke L_j assoziiert und wurde m im Zuordnungsverfahren aus Abschnitt 5.5 zum Merkmal $m' \in \mathcal{M}_t$ zugeordnet, dann kann angenommen werden, dass m' ebenfalls eine Observation von L_j ist.

Die Merkmalsverfolgung ist heuristisch und kann daher fehlerhafte Zuordnungen verursachen. Daher wird die Validität der Zuordnung von m' zu L_j durch die Kompatibilität in Winkel und Deskriptor überprüft. Dabei wird der Deskriptor des Merkmals d' mit dem ersten detektierten Deskriptor d in der Verfolgungskette verglichen, damit insbesondere während der ersten Detektionen einer Landmarke keine Drift im Deskriptor möglich ist. Wir nehmen an, dass beide Deskriptormessungen mit normalverteiltem Rauschen behaftet sind, d.h. $d \sim \mathcal{N}(\hat{d}, P_t)$ und $d' \sim \mathcal{N}(\hat{d}', P_t')$.

Ist die Zuordnungssicherheit $c_{match}(m, m')$ unterhalb eines Schwellwertes oder ist das Merkmal m' nicht kompatibel zu L_j, muss die Landmarke L_j modellgetrieben assoziiert werden.

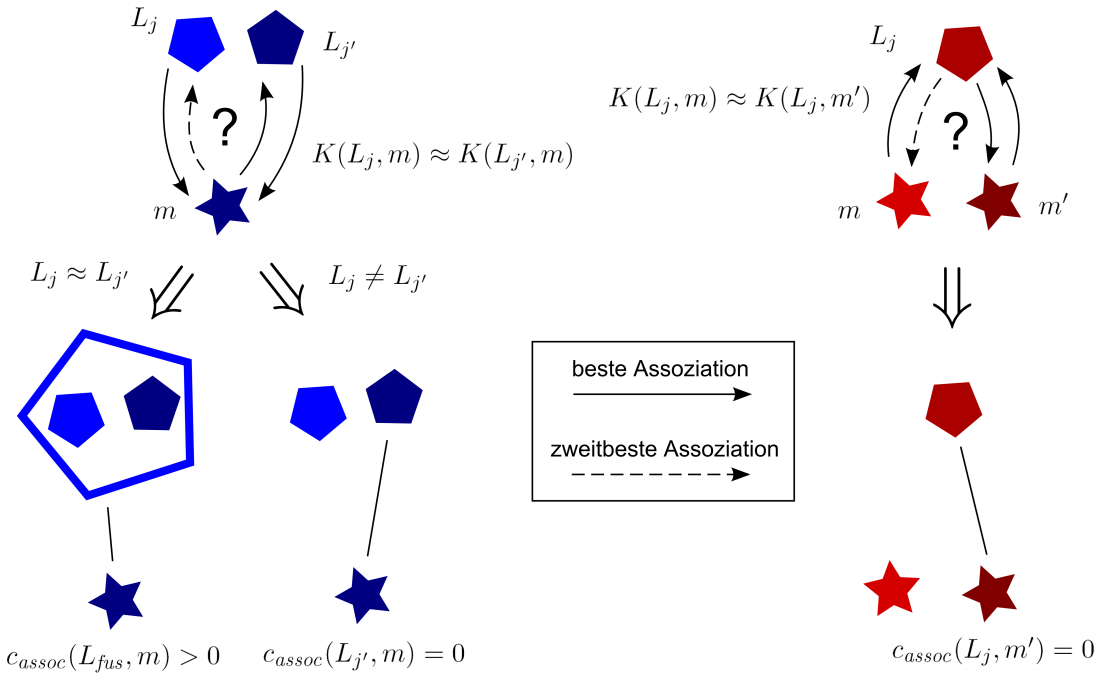

Abbildung 6.3: Illustration der Auflösung von zweifelhaften Datenassoziationen.

Als Maß für die Sicherheit in der Assoziation der Landmarke L_j mit dem Merkmal m' verwenden wir die Zuordnungssicherheit $c_{assoc}(L_j, m') = c_{match}(m, m')$ aus dem Zuordnungsverfahren. Die Sichtungssicherheit c_{obs} der Landmarke ist das Minimum aus Assoziationssicherheit und Detektionssicherheit des Merkmals: $c_{obs,j,t} = \min\left(c_{assoc}(L_j, m'), c_{m'}\right)$. Diese Assoziationsart besitzt folgende besondere Eigenschaften:

- Die Merkmalszuordnung wird nicht für jedes Partikel individuell hergestellt. Können Merkmale überwiegend über Bildsequenzen zugeordnet werden, wird der Aufwand für die modellgetriebene, partikelbasierte Datenassoziation erheblich reduziert.
- Die Validität kann in konstanter Zeit überprüft werden.

6.5.2 Modellgetriebene Datenassoziation

Existiert für eine sichtbare Landmarke L_j keine sichere ($c_{match} < c_{trust}$) oder kompatible Assoziation aus der Merkmalsverfolgung, kann sie modellgetrieben mit einem Merkmal aus $\mathcal{M}_t$ assoziiert werden. Die Menge der sichtbaren Landmarken bestimmen wir in der Posenschätzung $\left(\hat{s}_t^{[i]}, R_t^{[i]}\right)$. Eine Landmarke ist sichtbar, falls sie folgende Bedingungen erfüllt:

- Die mittlere Landmarkenposition $\mu_{j,t-1}$ ist von der mittleren Pose $\hat{s}_t^{[i]}$ maximal $d_{\max}$ entfernt.
- Die mittlere Landmarkenposition $\mu_{j,t-1}$ erscheint in der mittleren Pose $\hat{s}_t^{[i]}$ unter einem Winkel innerhalb des Sichtfelds des Roboters.
- Die mittlere Pose $\hat{s}_t^{[i]}$ erscheint in der mittleren Landmarkenposition $\mu_{j,t-1}$ unter einem Winkel innerhalb des möglichen Sichtbarkeitswinkelintervalls im Standpunkt

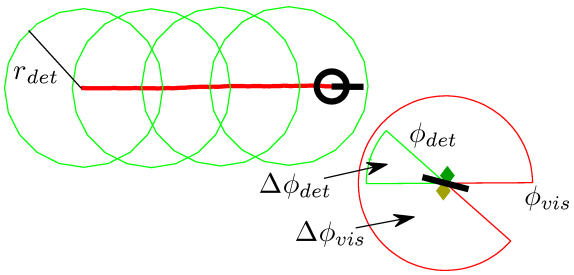

Abbildung 6.4: Beispiel für detektiertes Sichtbarkeitswinkelintervall im Standpunkt einer Landmarke ($[\phi_{det}, \phi_{det} + \Delta\phi_{det}]$, grün), mögliches Sichtbarkeitswinkelintervall ($[\phi_{vis}, \phi_{vis} + \Delta\phi_{det}]$, rot), und Umgebungen der erwarteten Sichtbarkeitsorte (grüne Kreise).

der Landmarke. Das mögliche Sichtbarkeitswinkelintervall von ϕ_{vis} bis $\phi_{vis} + \Delta\phi_{vis}$ ermitteln wir aus dem detektierten Sichtbarkeitswinkelintervall:

$$\begin{aligned} \phi_{vis} &= \phi_{det,j,t} + \Delta\phi_{det,j,t} - \pi \\ \Delta\phi_{vis} &= 2\pi - \Delta\phi_{det,j,t} \end{aligned}$$

Die Erweiterung des detektierten Sichtbarkeitswinkelintervalls ist durch die Annahme begründet, dass die Landmarke eine Struktur auf einer Wand darstellt, sodass das Merkmal im Standpunkt der Landmarke maximal innerhalb einer π-Erweiterung jeder Seite des detektierten Sichtwinkelintervalls observiert werden kann. Ein Beispiel findet sich in Abb. 6.4.

Die Datenassoziation wird durch einen modifizierten individuellen Kompatibilitätstest [29] hergestellt. Zunächst berechnen wir für jede sichtbare Landmarke nach Gl. (6.5) und Gl. (6.6) die Kompatibilität jedes Merkmals $m \in \mathcal{M}_t$ in Bildkoordinate und Deskriptor. Assoziationspaare, die zum Konfidenzlevel 95% inkompatibel sind, werden von der weiteren Betrachtung ausgeschlossen. Für jede Landmarke werden die beiden besten Merkmale gespeichert. Anschliessend wird die modellgetriebene Assoziation von Landmarken mit Merkmalen datengetrieben verifiziert, indem für Merkmale nur beste Assoziationen mit Landmarken hergestellt werden.

Besitzt eine Landmarke eine sichere Assoziation durch Merkmalsverfolgung, wird sie einer besten modellgetriebenen Assoziation mit einem anderen Merkmal bevorzugt. Die Überprüfung der Kompatibilität mit den restlichen Merkmalen im Bild wird für diese Landmarke daher nicht benötigt. Existiert eine unsichere aber kompatible Assoziation einer Landmarke mit einem Merkmal durch Merkmalsverfolgung, wird die beste modellgetriebene Assoziation mit einem anderen Merkmal nur hergestellt, falls ihre Sicherheit ein Vielfaches der Assoziationssicherheit der Merkmalsverfolgung beträgt. Beste Assoziationen von Merkmalen mit Landmarken ohne kompatible Assoziation durch Merkmalsverfolgung werden akzeptiert.

Die Assoziationssicherheit $c_{assoc,j,t}$ für eine Landmarke wird bestimmt, indem sowohl das Verhältnis zwischen den beiden besten Kompatibilitäten von Merkmalen für die Landmarke als auch zwischen den beiden besten Kompatibilitäten von Landmarken für das Merkmal betrachtet wird. Ein kleines Verhältnis führt zu einer geringen Assoziationssicherheit.

Besitzt die Assoziation eines Merkmals mit der Landmarke L_j eine Sicherheit $c_{assoc,j,t} = 0$ aufgrund einer ähnlich kompatiblen zweitbesten Assoziation mit einer weiteren Land-

marke, ist es möglich, dass die Landmarken redundant sind. Falls beste und zweitbeste Landmarke in ihrer Positionsschätzung kompatibel sind, werden die Landmarken fusioniert und das Merkmal mit der fusionierten Landmarke assoziiert.

Assoziationen mit Sicherheit $c_{assoc,j,t} = 0$ werden zwar hergestellt, aber wegen ihrer Unzuverlässigkeit nicht weiter verwendet. In Abb. 6.3 ist die Auflösung von zweifelhaften Zuordnungen illustriert. Die Sichtungssicherheit $c_{obs,j,t}$ der Landmarke ergibt sich auch für diese Assoziationsart aus dem Minimum aus Assoziationssicherheit und Detektionssicherheit des assoziierten Merkmals.

Die Laufzeit des Verfahrens liegt im ungünstigsten Fall in $O(MK_tN)$, falls für jedes Partikel die Kompatibilität jeder Landmarke zu allen Merkmalen berechnet werden muss. Um die sichtbaren Landmarken zu bestimmen, müssen bislang alle Landmarken in Betracht gezogen werden. In einer effizienten Implementierung könnten Landmarken in einem kd-Baum verwaltet werden, um die Menge der Landmarken innerhalb der maximalen Sichtweite mit effizienten Bereichsanfragen zu bestimmen. Da nur Winkelmessungen zur Verfügung stehen, können die Merkmale nach ihrem Ort sortiert werden, sodass bisher betrachtete Landmarken, die im Sichtwinkel inkompatibel zu vorhergehenden Merkmalen sind, für die weitere Betrachtung ausgeschlossen werden können.

6.6 Robuste Posenkorrektur und Ziehen von Partikelposen

In Abschnitt 6.3 wurde die Vorgehensweise erläutert, mit der im FastSLAM 2.0 Verfahren mehrere Observationen in einem Zeitschritt verarbeitet werden können. Die initiale Posenschätzung wird dabei rekursiv mit den Observationen korrigiert.

Um robust gegenüber Ausreissern in Merkmalsdetektion und Datenassoziation zu sein, verwenden wir einen RANSAC-Ansatz. RANSAC steht für Random Sample Consensus und wurde von Fischler und Bolles [37] entwickelt. Zur Posenkorrektur kommen offensichtlich nur assoziierte Landmarkenobservationen in Frage. Wir schätzen die Anzahl der benötigten Observationen $\hat{K}$ zur Erzeugung einer korrigierten Posenschätzung als $\hat{K} = \frac{1}{2}K^{[i]}_{assoc,t}$ ein. Für $K^{[i]}_{assoc,t} = 1$ korrigieren wir die Pose mit der einen Observation. Die Wahrscheinlichkeit für eine Observation nicht zu der Menge der Ausreisser zu gehören, schätzen wir mit $p_g = 0.9$ ab. Mit einer Fehlerwahrscheinlichkeit von $p_{fail} = 0.05$ erhalten wir die benötigte Anzahl der Iterationen $it_{fail} = \frac{\log(p_{fail})}{1-(p_g)^{\hat{K}}}$ des Algorithmus, um die Fehlerwahrscheinlichkeit zu garantieren. Die maximale Anzahl der Iterationen wird aus Effizienzgründen nach oben durch $it_{\max}$ beschränkt.

Die Eingabe des RANSAC-Posenkorrektur-Algorithmus setzt sich aus der aktuellen Menge der Landmarkenschätzungen $\mathcal{L}^{[i]}_{t-1} = \{\lambda^{[i]}_{j,t-1}\}_{j=1}^{N}$, den Landmarkenobservationen $\{z_{t,k}\}_{k=1}^{K_t}$ mit Varianzen $\{Q_{t,k}\}_{k=1}^{K_t}$ und Landmarkenkorrespondenzen $\{c^{[i]}_{t,k}\}_{k=1}^{K_t}$ und der aktuellen initialen Posenschätzung $\left(\hat{s}^{[i]}_t, R^{[i]}_t\right)$ des i-ten Partikels zusammen.

Das Verfahren wählt nun zufällig $\hat{K}$ assoziierte Observationen und korrigiert die initiale Posenschätzung zur Schätzung $(\mu_{s_t,init}, \Sigma_{s_t,init})$. Für die nicht in Betracht gezogenen, assoziierten Observationen wird einzeln die erhaltene Schätzung zu $(\mu_{s_t,test}, \Sigma_{s_t,test})$ aktualisiert und anschließend die Kompatibilität der Posenschätzungen ermittelt. Die Konsensusmenge $\mathcal{K}_{consensus}$ setzt sich aus den $\hat{K}$ Observationen und den kompatiblen restlichen Observationen zusammen. Gilt $|\mathcal{K}_{consensus}| \geq 0.8K^{[i]}_{assoc,t}$ werden die Observationen in der

Konsensusmenge als zuverlässig akzeptiert. Für Observationen, die nicht in der Konsensusmenge enthalten sind, wird die Assoziation von Landmarke mit Merkmal aufgelöst. Falls während der Iterationen des Verfahrens keine Konsensusmenge bestimmt werden konnte, werden sämtliche Assoziationen aufgelöst.

Diejenigen Assoziationen, die nicht aufgelöst wurden bzw. die in der Konsensusmenge enthalten sind, werden als zuverlässig angesehen und weiter verwendet. Mit diesen Observationen wird die initiale Posenschätzung zur Sampling-Verteilung $\left(\mu_{s_t}^{[i]}, \Sigma_{s_t}^{[i]}\right)$ korrigiert. Von der korrigierten Posenschätzung wird die Partikelpose $s_t^{[i]}$ gezogen:

$$s_t^{[i]} \sim \mathcal{N}\left(\mu_{s_t}^{[i]}, \Sigma_{s_t}^{[i]}\right)$$

6.7 Partikelgewichtung

Die Gewichte der Partikel nach Gl. (6.3) werden während der Berechnung der Sampling-Verteilung anhand der zuverlässig assoziierten Landmarken bestimmt. Mittelwert $\check{z}_k$ und Kovarianz Z_k der Normalverteilung in Gl. (6.4) werden während der Posenkorrektur berechnet, sodass sich die Observationswahrscheinlichkeit $p_{exp}(z_{t,k}|\check{z}_k)$ der Landmarke $l_{c_{t,k}}$ an dieser Stelle bestimmen lässt.

Wegen falscher Datenassoziationen ist es möglich, eine Landmarke im gesamten Bildbereich zu observieren. Die Observationswahrscheinlichkeit einer assoziierten Landmarke wird daher um einen uniformen Anteil erweitert:

$$w_{t,k}^{[i]} = \alpha_{uniform}\frac{1}{2} + (1 - \alpha_{uniform})p_{exp}(z_{t,k}|\check{z}_k)$$

Merkmalsobservationen, die nicht zuverlässig mit Landmarken assoziiert wurden, müssen mit einer geeigneten Observationswahrscheinlichkeit p_0 gewichtet werden, sodass die Assoziation des Merkmals durch andere Partikel keine niedrigere Observationswahrscheinlichkeit erhalten kann.

Um unmodellierten Abhängigkeiten zwischen den Landmarkenobservationen zu begegnen, diskontieren wir die Observationswahrscheinlichkeiten durch Potenzierung mit einem Faktor $\alpha_{discont} \in (0, 1]$, sodass sich das Gewicht des i-ten Partikels im Zeitpunkt t als

$$w_t^{[i]} = w_{t-1}^{[i]}\ \eta \prod_{k=1}^{K_t} \left(w_{t,k}^{[i]}\right)^{\alpha_{discont}}$$

ergibt.

6.8 Kartenaktualisierung

Wurden Landmarken mit Merkmalen assoziiert und die Partikelpose des i-ten Partikels für den aktuellen Zeitschritt t bestimmt, kann die Karte anhand der gezogenen Pose analog zum Algorithmus 2 aktualisiert werden. Unassoziierte Merkmale werden dabei als neue Landmarken in die Karte eingefügt. Da das Observationsmodell für reine Winkelmessungen nicht invertierbar ist, müssen neue Landmarkenpositionsschätzungen in der Tiefe geeignet initialisiert werden. Die Aktualisierung der Positionsschätzung einer Landmarke

wird durch eine iterierte EKF-Korrektur bewerkstelligt. Die Linearitätseigenschaften der Observationsmodelle werden berücksichtigt, indem die Parametrisierungen der Landmarkenschätzungen zu geeigneten Zeitpunkten gewechselt werden. Zusätzlich zur Position von Landmarken wird auch eine Schätzung des Deskriptors der Landmarke unterhalten. Landmarken mit geringer Detektionsrate oder unzuverlässiger Positionsschätzung müssen aus der Karte entfernt werden.

6.8.1 Initialisierung von Landmarken

Das reine Winkelobservationsmodell von Landmarken ist nicht invertierbar, sodass die Positionsschätzung der Landmarke bei der ersten Sichtung auf andere Weise initialisiert werden muss. Aufgrund der Nichtlinearität des kartesischen Observationsmodells bei hoher Unsicherheit in der Tiefe, verwenden wir zur Initialisierung die Parametrisierung in inverser Tiefe. Der erste Sichtungsort der Landmarke ist durch die gezogene Partikelpose sicher gegeben. Den globalen Winkel zu einer Landmarke initialisieren wir mit dem Observationswinkel $\phi := \arctan(\mathit{undistort}(z_t)) + \theta_t^{[i]}$ als Mittelwert und mit der mittleren Unsicherheit in der verzerrten Bildkoordinate $\sigma_\phi^2 := \left(\arctan\sqrt{Q_t}\right)^2$ als Näherung für die Varianz. Da die Tiefe der Landmarke unbekannt ist, wird ihr Mittelwert auf eine festgelegte Tiefe d_{init} gesetzt: $\rho := \frac{1}{d_{init}}$. Die Varianz σ_ρ^2 in der Tiefe soll zu nicht verschwindenden Anteilen den Tiefenbereich von naher Tiefe bis unendlicher Tiefe abdecken: $\sigma_\rho^2 := \left(\frac{2}{d_{init}}\right)^2$. Die Landmarkenpositionsschätzung wird also in inverser Tiefe im sicheren Ort $p_{j,t}$ der ersten Sichtung und Mittelwert und Kovarianz der normalverteilten Schätzung des globalen Winkels und der inversen Tiefe $(\mu_{j,t}, \Sigma_{j,t})$ wie folgt initialisiert:

$$
\begin{aligned}
p_{j,t}^{[i]} &:= \left(x_t^{[i]}, y_t^{[i]}\right)^T \\
\mu_{j,t}^{[i]} &:= (\phi, \rho)^T \\
\Sigma_{j,t}^{[i]} &:= \begin{pmatrix} \sigma_\phi^2 & 0 \\ 0 & \sigma_\rho^2 \end{pmatrix}
\end{aligned}
$$

6.8.2 Rekursive Landmarkenpositionsschätzung

Die Positionsschätzung einer assoziierten Landmarke $L_{c_{t,k}}$ wird mit der Observation des Merkmals in der verzerrten Bildkoordinate $z_{t,k}$ aktualisiert. Die Pose ist durch die gezogene Partikelpose $s_t^{[i]}$ gegeben. Mit dem entsprechenden Observationsmodell für die momentane Parametrisierung der Landmarke wird die Positionsschätzung in einer iterierten EKF-Korrektur (IEKF) [41] aktualisiert, da insbesondere Projektion und Linsenverzerrung Nichtlinearitäten im Observationsmodell verursachen, sodass mit dem iterierten Verfahren eine bessere Approximation möglich ist. Dazu wird in jeder Iteration der korrigierte Mittelwert der Landmarkenpositionsschätzung aus der letzten Iteration verwendet, um die ersten Ableitungen in Gl.(3.2) zu berechnen. Das Verfahren wird mit dem Mittelwert der Landmarkenpositionsschätzung aus dem letzten Zeitschritt initialisiert und mit einer festen Anzahl an Iterationen durchgeführt. Um die Sicherheit in Merkmalsdetektion und Assoziation zu berücksichtigen, wird die Kalman-Verstärkung durch Multiplizieren mit der Sichtungssicherheit $c_{obs,j,t}$ gewichtet.

6.8.3 Detektionsrate und erwartete Sichtbarkeit

Um Fehldetektionen von Landmarken feststellen zu können, ist ein Konzept zur Erwartung von Landmarkensichtungen notwendig. Eine Landmarke L_j soll in der Nähe von Orten detektierbar sein, in der sie bereits gesichtet wurde. Zusätzlich muss der Sichtwinkel zur Pose des Roboters im Standpunkt der Landmarke innerhalb des bereits detektierten Sichtbarkeitswinkelintervalls von $\phi_{det,j,t}$ bis $\phi_{det,j,t} + \Delta\phi_{det,j,t}$ liegen.

Für jede Landmarke wird eine Liste von Sichtbarkeitsorten gespeichert, in deren Umkreis mit festem Radius r_{det} die Sichtung der Landmarke erwartet wird. Befindet sich der Roboter in einer Position, deren minimale Entfernung d von allen Sichtbarkeitsorten größer als eine festgelegte Entfernung $d_{det} < r_{det}$ ist, wird die Position des Roboters als weiterer Sichtbarkeitsort in die Liste der Sichtbarkeitsorte der Landmarke eingefügt. Abb. 6.4 enthält ein Beispiel für detektiertes Sichtbarkeitsintervall und Sichtbarkeitsorte einer Landmarke.

Das detektierte Sichtbarkeitswinkelintervall im Standpunkt der Landmarke wird entsprechend der Pose des i-ten Partikels $s_t^{[i]}$ und der Landmarkenpositionsschätzung aktualisiert, indem eine normalverteilte Approximation $\left(\phi, \sigma_\phi^2\right)$ des aktuellen Sichtwinkels zur Roboterpose im Standpunkt der Landmarke bestimmt wird. Ist $\hat{l}$ die mittlere Landmarkenposition unter der Schätzung von L_j, ergibt sich der mittlere Sichtwinkel als $\phi = atan2\left(y_t^{[i]} - \hat{l}_y, x_t^{[i]} - \hat{l}_x\right)$. Es ist offensichtlich, dass aus dem Differenzvektor $v := \left(x_t^{[i]}, y_t^{[i]}\right)^T - \hat{l}$ nur dann stabil Winkel berechnet werden können, falls die Länge von v signifikant groß ist. Die Varianz erhält man durch Fehlerpropagation erster Ordnung. Da die erste Ableitung der Funktion für ϕ nach den Variablen der Landmarkenpositionsschätzung für $v_x \approx 0$ eine Singularität aufweist, muss die alternative Formulierung für die Berechnung von ϕ als Winkel zwischen dem Vektor $(1,0)^T$ und dem Differenzvektor v, $\phi = \arccos\left(\frac{v_x}{\|v\|}\right)$, zur Berechnung der Ableitung verwendet werden. Ist H_l die erste Ableitung dieser Funktion in der Parametrisierung der Landmarke nach den Variablen der Landmarkenpositionsschätzung ausgewertet in mittlerer Landmarkenposition und Partikelpose, beträgt die Varianz des Sichtwinkels $\sigma_\phi^2 = H_l \Sigma_{j,t} H_l^T$.

Bei der ersten Sichtung der Landmarke wird das detektierte Sichtbarkeitswinkelintervall mit Hilfe von $\left(\phi, \sigma_\phi^2\right)$ initialisiert, indem das Intervall auf die $3\sigma_\phi$-Umgebung um ϕ gesetzt wird, d.h. $\phi_{det,j,t} = cyc(\phi - 3\sigma_\phi, -\pi, \pi)$ und $\Delta\phi_{det,j,t} = 6\sigma_\phi$. Die Funktion $cyc(x, -T, T')$ bildet den Wert x in den zyklischen Wertebereich $(-T, T']$ ab, indem Vielfache von $(T' - T)$ zu x addiert werden.

Existiert bereits eine Schätzung für das Sichtbarkeitswinkelintervall, werden untere Intervallgrenze und Intervalllänge mit dem aktuellen Sichtwinkelbereich angepasst. Dazu überprüfen wir, ob das Intervall auf die Winkel $\phi \pm 3\sigma_\phi$ erweitert werden muss, indem die jeweils nächstgelegene Intervallgrenze zum observierten Sichtwinkel bestimmt und gegebenenfalls aktualisiert wird.

Die Detektionsrate $q_{det,j,t} := \frac{n_{det,j,t}}{n_{misdet,j,t}}$ der Landmarke L_j ist das Verhältnis von Detektionen $n_{det,j,t}$ zur Anzahl der Fehldetektionen $n_{misdet,j,t}$. Konnte die Landmarke im aktuellen Zeitschritt trotz Erwartung nicht detektiert werden, wird die Anzahl der Fehldetektionen um eins inkrementiert. Wurde die Landmarke mit einem Merkmal assoziiert, wird die Detektionszahl um die Sichtungssicherheit $c_{obs,j,t}$ erhöht. Dadurch ist die Detektionsrate gering, falls eine Landmarke häufig unsicher ($c_{obs,j,t} \approx 0$) detektiert und vergleichsweise

selten fehldetektiert wird.

6.8.4 Wechsel der Landmarkenparametrisierung

Wurde die Tiefe einer Landmarke L_j bereits hinreichend sicher geschätzt, wechseln wir zur kartesischen Parametrisierung, da die Linearität des Observationsmodells nicht mehr vom Verhältnis der ersten Sichtungstiefe zur aktuellen Sichtungstiefe abhängt. Zudem besitzt sie eine intuitivere Gestalt und bietet im späteren Verlauf Vorteile. Wir schätzen den sicheren Zeitpunkt zur Transformation der Parametrisierung in die kartesische Parametrisierung durch den Wert des Linearitätsindex L_d (Gl.(6.1)) ein. Der Index ist maximal für $|\cos(\alpha)| = 1$ mit dem Wert $L_{d,\max} = \frac{4\sigma_d}{\hat{d}'}$. Die minimale Tiefe $\hat{d}'$ approximieren wir mit der aktuellen mittleren Landmarkenposition $\mu_{j,t} = \left(\hat{\theta}_{j,t}, \hat{\rho}_{j,t}\right)$ und mit Hilfe der Sichtbarkeitsorte, in denen die Landmarke bisher detektiert wurde, indem die minimale Distanz zwischen Sichtbarkeitsorten und mittlerer Landmarkenposition bestimmt wird. Zusätzlich wird die Distanz von aktueller Partikelpose zur mittleren Landmarkenposition berücksichtigt. Die Varianz in der Tiefenschätzung approximieren wir durch Fehlerpropagation erster Ordnung aus der inversen Tiefenschätzung der Landmarke mit

$$\sigma_d^2 \approx H_\rho \sigma_\rho^2 H_\rho^T = \frac{\sigma_\rho^2}{\hat{\rho}_{j,t}^4}, \text{ mit } H_\rho := \nabla_\rho \left(\frac{1}{\rho}\right)\Big|_{\hat{\rho}_{j,t}} = -\frac{1}{\hat{\rho}_{j,t}^2}.$$

Die Varianz in der inversen Tiefe, σ_ρ^2, erhält man durch Marginalisierung der normalverteilten Landmarkenschätzung aus der zweiten Zeile und Spalte der Kovarianz $\Sigma_{j,t}$. Sinkt $L_{d,\max}$ unterhalb eines Schwellwerts, kann die Landmarkenpositionschätzung sicher in kartesischer Parametrisierung weitergeführt werden [40]. Die kartesische Parametrisierung ergibt sich wiederum durch Fehlerpropagation erster Ordnung:

$$\begin{aligned}
\mu'_{j,t} &= endpoint(p_{o,j}, \mu_{j,t}) \\
\Sigma'_{j,t} &= H_l \Sigma_{j,t} H_l^T \\
H_l &:= \nabla_{(\theta,\rho)^T} endpoint(p_o, (\theta,\rho)^T)\Big|_{p_{o,j},\mu_{j,t}}
\end{aligned}$$

6.8.5 Deskriptorschätzung

Da die extrahierten Deskriptoren der Bildmerkmale rauschbehaftet sind, nehmen wir normalverteiltes unkorreliertes Rauschen in den einzelnen Deskriptorkomponenten an und schätzen für jede Landmarke L_j neben dem Mittelwert $d_{j,t}$ der observierten Deskriptoren auch deren Standardabweichungen $\sigma_{d,j,t}$.

Ist die Landmarke L_j mit dem Merkmal $m \in \mathcal{M}_t$ assoziiert, können Mittelwert und Standardabweichung jeder Komponente k durch Anwendung des Verschiebungssatzes rekursiv aktualisiert werden:

$$\begin{aligned}
w_{j,t} &= w_{j,t-1} + c_{obs,j,t} \\
d_{j,t,k} &= \frac{1}{w_{j,t}} \left(w_{j,t-1} d_{j,t-1,k} + c_{obs,j,t} d_{m,k}\right) \\
d_{j,t,k}^{(2)} &= \frac{1}{w_{j,t}} \left(w_{j,t-1} d_{j,t-1,k}^{(2)} + c_{obs,j,t} d_{m,k}^2\right) \\
\sigma_{d,j,t,k}^2 &= d_{j,t,k}^{(2)} - d_{j,t,k}^2.
\end{aligned}$$

Dabei wird die Integration der Messung im Zeitschritt t mit der Sichtungssicherheit $c_{obs,j,t}$ gewichtet, um die Sicherheit in Merkmalsdetektion und Assoziation zu berücksichtigen.

6.8.6 Entfernen von Landmarken

Die Laufzeit des Verfahrens hängt wesentlich von der Anzahl der Landmarken ab. Außerdem führen fehlerhafte Datenassoziationen leicht zu divergierenden Positionsschätzungen. Da die Tiefe einer Landmarke nur über die Zeit durch Bewegungsparallaxe observiert werden kann, besteht die Gefahr, dass eine in der Tiefe unsicher initialisierte Landmarke nach einer grossen Zeitspanne, in der sie nicht observiert wurde, im stumpfen Winkel zur ersten Sichtlinie fälschlicherweise assoziiert wird.

Es ist daher wichtig, Landmarken nach geeigneten Kriterien aus der Karte zu entfernen:

a. Geringe Detektionsrate: Landmarken mit geringer Detektionsrate ($q_{det,j,t} < 0.5$) werden aus der Karte entfernt, da sie als Instanziierung instabiler und fälschlich detektierter Merkmale interpretiert werden.

b. Zu wenige Sichtungen: Liegt für eine Landmarke die Anzahl der Zeitschritte seit der letzten Sichtung oberhalb eines Schwellwertes und ist die Anzahl an Detektionen gering, wird sie entfernt, weil die Tiefen- und Deskriptorschätzungen unter Umständen nicht zuverlässig genug sind, um die Landmarke aus beliebigem Blickwinkel sicher zu reassoziieren.

c. Landmarke zu tief: Ist eine Landmarke in inverser Tiefe parametrisiert, ergibt sich die mittlere Tiefe vom ersten Sichtungsort direkt aus der Positionsschätzung. Wir nehmen an, dass die maximal observierbare Tiefe in der Umgebung beschränkt ist. Liegt die mittlere Tiefe vom ersten Sichtungsort überhalb dieser Schranke, muss die Landmarke entfernt werden. Vor allem bei falschen Datenassoziationen können so divergierende Schätzungen in inverser Tiefe festgestellt und bereinigt werden.

d. Nichtlineares inverses Tiefenmodell: Für Landmarken in inverser Tiefenparamatrisierung wird in bestimmten Fällen überprüft, ob der Linearitätsindex L_ρ in Gl. (6.1) unterhalb eines Schwellwerts von 0.5 liegt. Ansonsten wird die Landmarke gelöscht, da ihre Positionsschätzung aufgrund der Nichtlinearität im Observationsmodell divergieren kann. Wir unterscheiden die folgenden zwei Fälle:

- Der Roboter bewegt sich mit geringer Parallaxe auf ein Merkmal zu, sodass die Unsicherheit in der Tiefenschätzung kaum sinkt, aber das Verhältnis von Tiefe bei der ersten Sichtung zur aktuellen Tiefe steigt. Für einen Parallaxwinkel $\alpha = 0$ ist der Linearitätsindex maximal mit $L_{\rho,\max,1} := \frac{4\sigma_\rho}{\hat{\rho}} \left|1 - \frac{\hat{d}}{\hat{d}'}\right|$.
- Falls die Landmarke unsicher in der Tiefe geschätzt wurde, eine längere Zeit nicht observiert werden konnte und anschließend erneut entlang einer Sichtlinie observiert wird, die im stumpfen Winkel auf die erste Sichtlinie steht, ist das Observationsmodell stark nichtlinear. Daher wird für Landmarken in inverser Tiefenparametrisierung, die eine bestimmte Anzahl von Zeitschritten nicht observiert wurden, überprüft, ob der Linearitätsindex für $|cos(\alpha)| = 0$, $L_{\rho,\max,2} := \frac{4\sigma_\rho}{\hat{\rho}}$, unterhalb des Schwellwerts liegt.

Die mittlere Tiefe bzw. inverse Tiefe, $\hat{d}$ bzw. $\hat{\rho}$, ergibt sich aus der Distanz bzw. inversen Distanz von Ort der ersten Sichtung zur mittlerer Position der Landmarke. Die minimale Tiefe $\hat{d}'$ schätzen wir wie zuvor in Abschnitt 6.8.4 anhand der Sichtbarkeitsorte, der Partikelpose und der Landmarkenpositionsschätzung ein. Die Varianz σ_ρ^2 in der inversen Tiefe erhält man durch Marginalisierung aus der zweiten Zeile und Spalte der Landmarkenkovarianz $\Sigma_{j,t}$.

6.9 Erneuerung der Partikelmenge

Nach der Kartenaktualisierung wird die Partikelmenge gemäß der Gewichtung der Partikel erneuert, falls die Anzahl der effektiven Partikel M_{eff} unterhalb des Schwellwerts $\chi_{eff} = \frac{1}{2}M$ sinkt (s. Abschnitt 3.3.2). Als Resampling-Strategie verwenden wir das Low-Variance-Sampling-Verfahren. Aus Zeitgründen konnte in dieser Arbeit die effiziente Baumstruktur für das FastSLAM-Verfahren, die von Montemerlo et al. [10] vorgeschlagen wird, nicht implementiert werden.

7 Erzeugung und Verwendung eines Wandmodells

In den vorangegangenen Kapiteln wurde erläutert, wie in den eindimensionalen Bildern Kanten- und Blobmerkmale in Helligkeit und Farbe detektiert werden. Diese Kanten und Blobmerkmale werden als Observationen der Umgebungsstruktur aufgefasst. Visuelle punktförmige Landmarken werden als Repräsentation der Umgebungsstruktur in die Karte eingefügt, deren kartesischer Ort durch Bewegungsparallaxe aus den Merkmalsobservationen geschätzt wird.

Im diesem Kapitel wird ein Verfahren vorgestellt, das die kartierten Kantenlandmarken zu einem Wandmodell verknüpft. Wir nehmen an, dass Kanten an Grenzen zwischen gleichförmigen und geradlinigen Wandsegmenten in der Umgebung auftreten. Ein solches Wandsegment erscheint im Bild als gleichförmige Ausdehnung zwischen den begrenzenden Kanten, sodass deren Beschreibungen auf den entsprechenden Seiten zum Segment kompatibel zu einem überwiegenden Teilbereich innerhalb des Segments ist.

Da Tiefe nicht direkt observierbar ist und die begrenzenden Kanten der Wandsegmente bereits als visuelle Landmarken in der Karte repräsentiert sind, modellieren wir Wandsegmente als geradlinige Verbindung zwischen Kantenlandmarken. Die Unsicherheit in Ort und Orientierung der Wandsegmente hängt also von der Unsicherheit in der Positionsschätzung der unterstützenden Landmarken ab.

Das Wandmodell kann in vielfältiger Weise verwendet werden. Im SLAM-Verfahren kann modellgetrieben Tiefe in Bereichen zwischen Landmarken inferiert werden. Dadurch ist es beispielsweise möglich auf Verdeckungen von Landmarken zu schliessen oder Landmarken bei ihrer ersten Sichtung in der mittleren Tiefe geeignet zu initialisieren. Durch die probabilistische Formulierung wird Unsicherheit in Ort und Ausrichtung von Wandsegmenten berücksichtigt.

7.1 Probabilistische Beschreibung von Wänden

Wandsegmente werden durch ihre beiden begrenzenden Kantenlandmarken unterstützt. Wir parametrisieren deshalb Wandsegmente in Abhängigkeit von den Positionsschätzungen der Landmarken. Die Unsicherheit in den Landmarkenpositionen überträgt sich damit auf die Unsicherheit in Ort und Orientierung der Wand.

Seien L_{left} und L_{right} Kantenlandmarken an den Positionen l_{left} und l_{right}. Der Ort m_w des Wandsegments $w = \overline{L_{left}L_{right}}$ lässt sich als Mittelpunkt zwischen den Positionen der Landmarken beschreiben. Die Orientierung beschreiben wir als den halbierten Differenzvektor d_w zwischen den Landmarkenpositionen. Die Wandparameter sind Funktionen im Ort der Landmarken:

$$x_w(l_{left}, l_{right}) := \begin{pmatrix} m_w(l_{left}, l_{right}) \\ d_w(l_{left}, l_{right}) \end{pmatrix} = \begin{pmatrix} \frac{1}{2}\left(l_{left} + l_{right}\right) \\ \frac{1}{2}\left(l_{left} - l_{right}\right) \end{pmatrix}$$

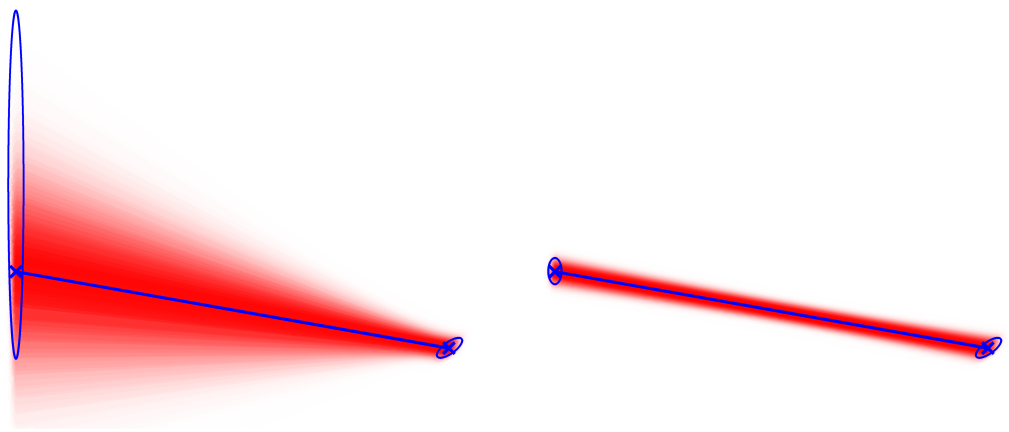

Abbildung 7.1: Beispiele für die normalverteilte Schätzung eines Wandsegments zwischen zwei unterstützenden Landmarken. Die Mittelwerte der Landmarkenpositionen werden als blaue Kreuze dargestellt, die blauen Ellipsen geben die σ-Umgebung der Positionsschätzungen wieder. Die blaue Gerade zwischen den Landmarken illustriert das mittlere Wandsegment. Von der normalverteilten Schätzung wurden 10000 Stichproben gezogen und mit wachsender Wahrscheinlichkeit zunehmend rot eingezeichnet.

Die approximative, normalverteilte Schätzung (μ_w, Σ_w) der Wandsegmentparameter ergibt sich durch Fehlerpropagation erster Ordnung:

$$\mu_w = x_w(\mu_{left}, \mu_{right})$$

$$\Sigma_w = H_l \begin{pmatrix} \Sigma_{left} & \begin{matrix} 0 & 0 \\ 0 & 0 \end{matrix} \\ \begin{matrix} 0 & 0 \\ 0 & 0 \end{matrix} & \Sigma_{right} \end{pmatrix} H_l^T$$

$$H_l := \nabla_{(l_{left}, l_{right})^T} x_w(l_{left}, l_{right}) \Big|_{(\mu_{left}, \mu_{right})^T}$$

Abb. 7.1 illustriert Beispiele des Wandmodells für unterstützende Landmarken unterschiedlicher Unsicherheit in der Tiefe. Die Schätzung des rechten Wandsegments enthält Segmente, die mit zunehmender Unsicherheit in den unterstützenden Landmarkenpositionen in ihrer Wahrscheinlichkeit abnehmen. Die normalverteilte Approximation für die Verteilung der Wandsegmente ist offenbar eine gute Näherung. Im linken Wandsegment ist die linke Landmarke in inverser Tiefe parametrisiert und deutlich unsicherer in der Tiefenschätzung als die rechte Landmarke. Die Verteilung der Segmente ist auf der linken Seite des Wandsegments eine grobe Approximation, da die kartesische Darstellung des Wandsegments die Unsicherheit in der inversen Tiefe nicht repräsentieren kann. Wandsegmente sollten also nur von Landmarken unterstützt werden, die bereits ausreichend sicher in der Tiefenschätzung oder kartesisch parametrisiert sind.

Analog zur Detektionsrate von Landmarken wird die Existenz von Wandsegmenten rekursiv geschätzt, um eventuelle Fehldetektionen aus der Karte entfernen zu können. Solche Fehldetektionen werden durch virtuelle Kanten an Tiefensprüngen verursacht, die fälschlicherweise als Seite eines Wandsegments aufgefasst werden, da nur visuelle Kri-

terien für die Existenz von Wandsegmenten überprüft werden. Sobald Merkmale durch diese virtuellen Wandsegmente hindurch wahrgenommen werden oder der Roboter sich hindurch bewegt, kann die Existenz dieser Wände ausgeschlossen werden.

Aus diesem Grund schätzen wir mit den Observationen $z^w_{1:t}$ von positiven und negativen Sichtungen eines Wandsegments w dessen Existenzwahrscheinlichkeit $bel_t(e_w) = p(e_w|z^w_{1:t})$. Das probate Mittel zur rekursiven Schätzung dieses statischen binären Zustands ist das rekursive Filter aus Abschnitt 3.3.3.

Wandsegmente werden repräsentiert, indem für jede Kantenlandmarke eine Liste von Verknüpfungen zu Wandsegmenten mit anderen Landmarken aufrechterhalten wird. In dieser Liste wird zu jeder Verknüpfung die betroffene Seite der Kante und die Existenzwahrscheinlichkeit in Form des logarithmischen Verhältnisses $l_{t,w} = log\frac{p(e_w|z^w_{1:t})}{1-p(e_w|z^w_{1:t})}$ gespeichert.

7.2 Observation und Existenz von Wänden

Observation von Wänden

Um positive bzw. negative Sichtungen von Wandsegmenten aus dem Bild zu extrahieren, müssen eine Reihe von Kriterien zwischen im Bild benachbarten assoziierten Kantenlandmarken überprüft werden. Damit die Anzahl der verwalteten Wandsegmente für eine Landmarke gering gehalten wird, müssen bei der Initialisierung eines Segments zusätzliche Bedingungen erfüllt sein.

Die Kantenmerkmale $m \in \mathcal{M}_t$ werden nach ihrem detektierten Ort in aufsteigender Reihenfolge sortiert. Für jedes Merkmal in der sortierten Liste, das mit einer Landmarke L assoziiert wurde, werden eine Reihe von Bedingungen überpüft, die zu einer Sichtung eines Wandsegments führen:

- Das nächste Merkmal in der Liste ist mit einer Landmarke L' assoziiert.
- Die Unsicherheit σ_d in der Tiefenschätzung einer der Landmarken L, L' ist gering. Für Landmarken in inverser Tiefenparametrisierung wird die Unsicherheit wie in Abschnitt 6.8.4 bestimmt. Die Tiefenunsicherheit für kartesisch parametrisierte Landmarken wird als Wurzel des grössten Eigenwerts der Kovarianz in der Positionsschätzung berechnet.
- Die Unsicherheit in der Tiefenschätzung der anderen Landmarke ist ebenfalls gering, sodass die normalverteilte Approximation eines Wandsegments ausreichend gut ist.
- Die Landmarkendeskriptoren auf dem potentiellen Wandsegment sind kompatibel.
- Der Bildbereich zwischen den Landmarken ist kompatibel zum interpolierten Deskriptor der Landmarken. Um dies zu überprüfen, wird der Bildbereich zwischen den zugehörigen Merkmalen abgetastet. Ort und Skala der Abtastpunkte werden derart gewählt, dass das Bild ausgehend von Ort und Skala des einen Merkmals in der Pyramide bis zu Ort und Skala des anderen Merkmals durchlaufen wird. Für die Helligkeits- und Farbwerte eines untersuchten Abtastpunktes wird überprüft, ob sie zum linear interpolierten Deskriptor der beiden Landmarken kompatibel sind. Die Interpolation wird gemäß der Position des Abtastpunkts zwischen den Merkmalen durchgeführt.
- Falls das Wandsegment nicht initialisiert ist, darf das potentielle mittlere Wandsegment zwischen den Landmarken kein mittleres sichtbares Wandsegment w' schnei-

den, das von keiner der betrachteten Landmarken unterstützt wird. Die Überprüfung wird mit den Schnittpunkten der mittleren Wandsegmenten durchgeführt, wobei Überschneidungen am Randbereich der sichtbaren Wandsegmente erlaubt werden. Schneiden sich die Segmente, müssen die Landmarken auf dem Segment w' liegen. Eine zusätzliche Bedingung für die Initialisierung ist, dass der Sichtwinkel auf beide betrachteten Landmarken in der aktuellen Pose nicht zu spitz ist, da die Aussage über die Kompatibilität des Bildbereichs zwischen den Landmarken in diesem Falle von zu wenigen Stichproben gestützt wäre. Sind diese zusätzlichen Bedingungen erfüllt, wird die positive Sichtung $z_t^w = conn$ erzeugt und das Wandsegment w initialisiert.

- Falls das Wandsegment bereits initialisiert wurde und die Bedingungen erfüllt sind, wird eine positive Sichtung $z_t^w = conn$ erzeugt, ansonsten eine negative ($z_t^w = noconn$).

Wie bereits erwähnt, werden negative Sichtungen in die Existenzschätzung der Wandsegmente integriert, um virtuelle Wandsegmente an Tiefensprüngen zu entfernen. Wird der Roboter im folgenden Zeitschritt ein sichtbares Wandsegment durchqueren oder wurde eine Landmarke hinter einem sichtbaren Wandsegment observiert, wird deshalb eine negative Sichtung $z_t^w = impl$ generiert.

Test auf Durchquerung von Wänden

Um einzuschätzen, ob der Roboter im nächsten Zeitschritt ein sichtbares Wandsegment durchqueren wird, muss zunächst die im folgenden Zeitschritt zurückgelegte Strecke abgeschätzt werden. Die Vorhersage ist aus Effizienzgründen notwendig, da ansonsten jedes Wandsegment in der Karte untersucht werden müsste. Stattdessen wird die Menge der sichtbaren Wandsegmente verwendet, die vor der Aktualisierung der Wandsegmente bestimmt wird (s. Abschnitt 7.3).

Die Differenz der letzten beiden Posen des i-ten Partikels $\Delta s = s_t^{[i]} - s_{t-1}^{[i]}$ wird dazu verwendet, eine Näherung $\Delta\tilde{s}$ der im nächsten Zeitschritt zurückgelegten Strecke zu berechnen. Die Länge dieser Strecke soll in der Norm mindestens $\Delta s_{\min} = 0.1$ betragen, d.h. $\Delta\tilde{s} = \max(\|\Delta s\|, \Delta s_{\min})\frac{\Delta s}{\|\Delta s\|}$. Das Wandsegment w mit Parametern m_w und d_w wird durchquert, falls der mittlere Schnittpunkt der Geraden $\gamma_s : x = s_t^{[i]} + \lambda_s \Delta\tilde{s}$ und $\gamma_w : x = m_w + \lambda_w d_w$ auf dem Wandsegment liegt, d.h. $|\lambda_w| < 1$, und die Wahrscheinlichkeit $p(0 \leq \lambda_s \leq 1)$, dass der Schnittpunkt auf der vorhergesagten Strecke liegt, einen Schwellwert überschreitet. Diese Wahrscheinlichkeit approximieren wir, indem die Schnittpunktgleichung nach λ_s aufgelöst wird, und eine normalverteilte Schätzung $(\mu_{\lambda_s}, \Sigma_{\lambda_s})$ für λ_s durch Fehlerpropagation erster Ordnung bestimmt wird:

$$\begin{aligned}
\lambda_s(s_p, s_d, m_w, d_w) &:= \frac{d_{w,y}}{s_{d,x}d_{w,y} - d_{w,x}s_{d,y}}(m_{w,x} - s_{p,x}) \\
&\quad - \frac{d_{w,x}}{s_{d,x}d_{w,y} - d_{w,x}s_{d,y}}(m_{w,y} - s_{p,y}) \\
\mu_{\lambda_s} &:= \lambda_s(s_t^{[i]}, \Delta\tilde{s}, \mu_w) \\
\Sigma_{\lambda_s} &:= H_w \Sigma_w H_w^T
\end{aligned}$$

Anschließend ergibt sich die gesuchte Wahrscheinlichkeit als $p(0 \leq \lambda_s \leq 1) \approx F(1; \mu_{\lambda_s}, \Sigma_{\lambda_s}) - F(0; \mu_{\lambda_s}, \Sigma_{\lambda_s})$ mit der kumulativen Verteilungsfunktion $F(x; \mu, \Sigma)$ der

Normalverteilung.

Test auf Verdeckungen von Landmarken durch Wände

Um zu überprüfen, ob sich eine assoziierte Landmarke hinter einem sichtbaren Wandsegment befindet, schliessen wir aus, dass die unsichere Landmarke weder auf noch vor dem Wandsegment liegt. Es werden nur solche Landmarken weiter untersucht, die innerhalb des Sichtwinkelbereichs des Wandsegments beobachtet werden. Anschliessend wird festgestellt, ob die Landmarke mit hoher Wahrscheinlichkeit auf dem Wandsegment liegt. Dafür werden die Unsicherheit in Landmarkenposition und Wandsegmentparametrisierung berücksichtigt. Gerade für Landmarken, die in ihrer Tiefenschätzung eine hohe Unsicherheit enthalten, ist ein probabilistischer Test wichtig, da die Betrachtung des Mittelwerts der Positionsschätzung allein für eine zuverlässige Entscheidung nicht ausreicht. Die Unsicherheit in der Lage des Wandsegments muss aus analogem Grund ebenfalls betrachtet werden.

Die Landmarke L mit Position l liegt auf dem Wandsegment w mit Parametern $x_w = (m_w, d_w)^T$, falls ein $\lambda \in \mathbb{R}$ existiert, sodass $l = m_w + \lambda d_w$. Setzen wir $l_x = m_{w,x} + \lambda_x d_{w,x}$ und $l_y = m_{w,y} + \lambda_y d_{w,y}$, ist dies äquivalent zu $\lambda_x = \lambda_y$ bzw. $\lambda_x - \lambda_y = 0$. Definieren wir eine stochastische Variable $v := \lambda_x - \lambda_y = (l_x - m_{w,x})d_{w,x} - (l_y - m_{w,y})d_{w,y}$, kann unter den Schätzungen für l und w die Wahrscheinlichkeit $p(v|l, w)$ approximativ bestimmt werden. Sei w durch L_{left} und L_{right} unterstützt. Wir verwenden Fehlerpropagation erster Ordnung, um eine normalverteilte Approximation (μ_v, σ_v^2) für $p(v|l, w)$ zu erhalten:

$$\begin{aligned}
v(l, l_{left}, l_{right}) :=& (l_x - m_{w,x}(l_{left}, l_{right}))d_{w,x}(l_{left}, l_{right}) \\
&- (l_y - m_{w,y}(l_{left}, l_{right}))d_{w,y}(l_{left}, l_{right}) \\
\mu_v :=& v(\mu_l, \mu_{left}, \mu_{right}) \\
\sigma_v^2 :=& H_l \Sigma_l H_l^T + H_w \Sigma_w H_w^T \\
H_l :=& \nabla_l \; v(l, l_{left}, l_{right})|_{\mu_l, \mu_{left}, \mu_{right}} \\
H_w :=& \nabla_{(l_{left}, l_{right})^T} \; v(l, l_{left}, l_{right})\Big|_{\mu_l, \mu_{left}, \mu_{right}}
\end{aligned}$$

Wir nehmen an, dass die Landmarke L auf w liegt, falls der Innovationstest $\frac{\Delta v^2}{\sigma_v^2} < \chi^2_{1,\alpha}$ mit $\Delta v := 0 - \mu_v$ erfüllt ist. Für diesen Test wird angenommen, dass der Sichtwinkel zur untersuchten Landmarke innerhalb des Sichtwinkelbereichs zu den unterstützenden Landmarken des Wandsegments liegt, was zuvor gewährleistet wurde. Dieser Test wird auch verwendet, um für die Initialisierung von Wandsegmenten zu entscheiden, ob die untersuchten Landmarken auf schneidenden Wandsegmenten liegen. Liegt die Landmarke nicht auf der Wand, genügt es zu überprüfen, ob der Schnittpunkt der mittleren Sichtlinie zur Landmarke mit dem mittleren Wandsegment vor oder hinter dem Wandsegment liegt. Beispiele für die Wahrscheinlichkeit $p(v|l, w)$ für unterschiedliche Unsicherheiten in Landmarkenposition und Wandsegment sind in Abb. 7.2 dargestellt.

Randzeiger

Der begrenzte Blickwinkelbereich der Kamera schränkt die Methode zur Observation von Wänden ein. Die Idee ist hier, Wandsegmente auch für unterstützende Landmarken observieren zu können, die zuletzt aus dem Blickwinkelbereich geraten sind. Dazu speichern

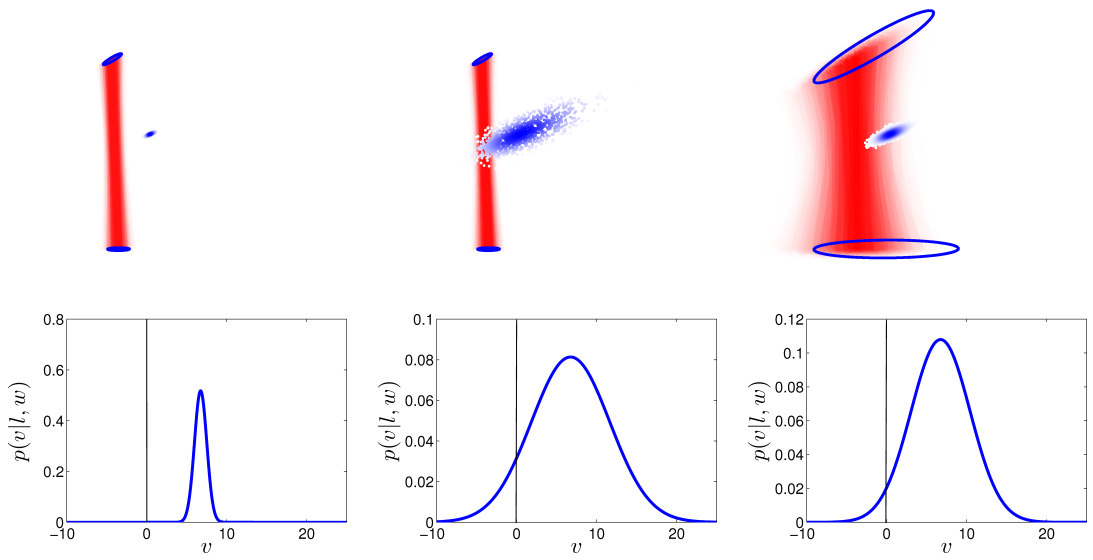

Abbildung 7.2: Beispiele für den Test, ob Landmarken auf Wandsegmenten liegen. Obere Reihe: Wandsegmente und Landmarken mit unterschiedlichen Unsicherheiten. Untere Reihe: Wahrscheinlichkeit $p(v|l,w)$ der Landmarke auf dem Wandsegment zu liegen. Links: Wandsegment und Landmarke sind in ihrer Schätzung sicher und liegen nicht aufeinander. Mitte: Die unsichere Landmarke liegt auf dem sicheren Wandsegment. Rechts: Aufgrund der Unsicherheit in Landmarken- und Wandsegmentschätzung kann nicht ausgeschlossen werden, dass die Landmarke auf dem Wandsegment liegt.

wir für jeden Bildrand zunächst die äußerste assoziierte Landmarke als Kandidaten für die Randlandmarke. Wird ein Kandidat in folgenden Zeitschritten nicht assoziiert und liegt der erwartete Observationswinkel ϕ_{exp} außerhalb des Bildes aber in der Hemisphäre des Bildrands ($\pi > \phi_{exp} > \frac{1}{2}\alpha_{FOV}$ für den linken bzw. $-\frac{1}{2}\alpha_{FOV} > \phi_{exp} > -\pi$ für den rechten Bildrand), wird der Randlandmarkenzeiger auf den Kandidaten gesetzt. Der Zeiger auf die Randlandmarke wird zurückgesetzt, falls sie reassoziiert wurde, der Deskriptor der Landmarke auf der zum Rand zugewandten Seite nicht mehr kompatibel mit dem Bildrand ist oder der Sichtwinkel zur Landmarke innerhalb des Blickwinkelbereichs oder außerhalb der Hemisphäre des Bildrands liegt. Ist der Zeiger auf eine Landmarke gesetzt, wird für die Landmarke ein virtuelles Kantenmerkmal mit Bildrand als Ort und mittlerer Kantendetektionsskala als Skala in die sortierte Liste der observierten Kantenmerkmale aufgenommen. Auf diese Weise werden die üblichen Kriterien für die Sichtung eines Wandsegments berücksichtigt, wobei nur der Bereich von Bildrand bis zum observierten Kantenmerkmal überprüft wird.

Rekursive Existenzschätzung

Für die a-priori-Wahrscheinlichkeit der Existenz einer Wand nehmen wir den Wert $p(e_w) = 0.5$ an, was einem logarithmischen Verhältnis von $l_{w,0} = log(1) = 0$ entspricht. Um die Sichtung z_t^w in die Schätzung für $p(e_w|z_{1:t}^w)$ integrieren zu können, schätzen wir die diagnostischen Wahrscheinlichkeiten $p(e_w|z_t^w)$ für $z_t^w \in \{conn, noconn, impl\}$ mit fol-

genden Werten ab:

$$\begin{aligned} p(e_w|conn) &= 0.6 \\ p(e_w|noconn) &= 0.4 \\ p(e_w|impl) &= 0.001 \end{aligned}$$

Mit diesen Wahrscheinlichkeiten wird die Existenzschätzung für eine observierte Wand w im Zeitschritt t folgendermassen aktualisiert:

$$l_{w,t} := l_{w,t-1} + log\frac{p(e_w|z_t^w)}{1 - p(e_w|z_t^w)}$$

In der Implementierung werden Verknüpfungen von Landmarken aus Effizienzgründen entfernt, falls die Existenzwahrscheinlichkeit nur geringfügig von $p(e_w) = 0.5$ abweicht.

Die Aktualisierung der Wandrepräsentation wird für jedes Partikel nach der Aktualisierung der Karte durchgeführt.

7.3 Bestimmung der sichtbaren Wandsegmente

Die sichtbaren Wandsegmente in der Pose des Roboters werden zur Datenassoziation und zum Kartieren von Landmarken verwendet. Um sie zu bestimmen, muss für jede Landmarke, die vor dem Roboter in einem bestimmten Entfernungsbereich liegt, untersucht werden, welche der unterstützten Segmente den Sichtwinkelbereich des Roboters schneiden.

Für alle Landmarken L in der Menge

$$\mathcal{L}_{front}^{[i]} := \left\{ L \in \mathcal{L}_t^{[i]} \middle| \left\| (x_t^{[i]}, y_t^{[i]})^T - \hat{l} \right\| \leq d_{\max} \wedge \left| angleto(localtransform(\hat{l}, s_t^{[i]})) \right| < \frac{\pi}{2} \right\}$$

bestimmen wir für jede Landmarke L', die mit L zu einem Wandsegment verknüpft ist, den mittleren Sichtwinkel $\beta = angleto(localtransform(\hat{l}', s_t^{[i]}))$, wobei $angleto((x,y)^T) := arctan2(y,x)$. Den Winkel zur Landmarke L bezeichnen wir mit $\alpha = angleto(localtransform(\hat{l}, s_t^{[i]}))$.

Das Wandsegment zwischen L und L' ist in folgenden drei Fällen sichtbar:

- Die Landmarke L liegt innerhalb des Sichtbereichs des Roboters ($\frac{1}{2}\alpha_{FOV} \geq \alpha \geq -\frac{1}{2}\alpha_{FOV}$). Dann kann L' in beliebigem Winkel erwartet werden.
- Die Landmarke L liegt links außerhalb des Sichtbereichs ($\frac{1}{2}\pi > \alpha > \frac{1}{2}\alpha_{FOV}$). Landmarke L' muss zwischen dem linken Bildrand und $\alpha - \pi$ liegen, d.h. $\frac{1}{2}\alpha_{FOV} > \beta > \alpha - \pi$.
- Die Landmarke L liegt rechts außerhalb des Sichtbereichs ($-\frac{1}{2}\alpha_{FOV} > \alpha > -\frac{1}{2}\pi$). Landmarke L' muss zwischen dem rechten Bildrand und $\alpha + \pi$ liegen, d.h. $\alpha + \pi > \beta > -\frac{1}{2}\alpha_{FOV}$.

Die sichtbaren Wandsegmente werden in einer Liste gespeichert, die für jedes Wandsegment die unterstützenden Landmarken sowie Start- und Endsichtwinkel zu den Landmarken enthält. Um diese Liste effizienter durchsuchen zu können, werden die sichtbaren Wandsegmente aufsteigend nach Startwinkel sortiert: Sollen für einen Sichtwinkel nur

diejenigen Wandsegmente bestimmt werden, für die der Sichtwinkel zwischen den unterstützenden Landmarken des Segments liegt, kann die Iteration durch die Liste der sichtbaren Segmente abgebrochen werden, falls der Startwinkel größer als der untersuchte Sichtwinkel ist.

Da jedes Partikel eine individuelle Karte schätzt, müssen die sichtbaren Wandsegment für jedes Partikel individuell bestimmt werden. Im ungünstigsten Fall könnte jede Landmarke mit jeder anderen Landmarke zu einem Wandsegment verknüpft sein, sodass die Laufzeit des Verfahrens in $O(MN^2 log(N^2))$ läge. Man kann jedoch die Anzahl der möglichen Verknüpfungen einer Landmarke durch eine konstante Zahl k abschätzen, wenn man annimmt, dass eine Kante durch eine Umgebungsstruktur hervorgerufen wird, die beidseitig ist und nicht Kante von Strukturen in unendlich vielen Skalen sein kann. Unter dieser Annahme liegt die Laufzeit in $O(MNlog(N))$.

Aus der Posenänderung im letzten Zeitschritt könnte auf die Änderung des Sichtwinkelbereichs geschlossen werden, sodass eine effizientere Implementierung möglich ist, die die Liste der sichtbaren Wandsegmente inkrementell aktualisiert. Das Verfahren kann außerdem verbessert werden, indem zusätzlich zur Forderung, dass unterstützende Landmarken innerhalb eines Entfernungsbereichs liegen, Verdeckungen von Wandsegmenten berücksichtigt werden, sodass die Effizienz von Verfahren erhöht wird, die die Liste der sichtbaren Wandsegmente durchsuchen.

7.4 Verbesserung des Kartierens von Landmarken durch Wände

Mit den gewonnenen Wandsegmenten kann das Kartieren von Landmarken verbessert werden, da sie modellgetrieben Tiefeninformation liefern. Damit können Landmarken z.B. in der Tiefe initialisiert und Sichtbarkeitskonzepte erweitert werden.

7.4.1 Tiefeninitialisierung

Stehen nur Winkelobservationen von punktförmigen Landmarken zur Verfügung, können Roboterpose und Landmarkenpositionen bis auf eine nicht observierbare Skalierung rekonstruiert werden. Das bedeutet, dass bei Unsicherheit in der Odometrie die Skalierung der Karte zu einem zusätzlichen freien Parameter wird. Piniés et al. [42] belegen, dass in diesem Fall die Initialisierung der inversen Tiefe einen wesentlichen Einfluss auf die Unter- bzw. Überschätzung der Skala hat. Wir verwenden das Wandmodell, um die initiale mittlere Tiefe von Landmarken auf die Entfernung von Roboterpose zum nahegelegensten Wandsegment zu initialisieren. Dazu wird die Liste der sichtbaren Wandsegmente durchlaufen, um diejenigen existierenden Wandsegmente zu finden, zwischen deren Start- und Endwinkel der mittlere Sichtwinkel zur Landmarke liegt. Die initialie Tiefe d der Landmarke ergibt sich als d_{init}, falls kein Wandsegment bestimmt werden kann, oder als minimale Entfernung zum Schnittpunkt der mittleren Wandsegmente mit der mittleren Sichtlinie zur Landmarke. Die Varianz in der inversen Tiefe initialisieren wir mit $\sigma_\rho = \frac{2}{d}$, um einen weiten Bereich von nahen Tiefen bis unendlicher Tiefe abzudecken.

7.4.2 Datenassoziation

Sichtbarkeitswinkelintervall

Bisher wurde das mögliche Sichtbarkeitswinkelintervall im Standpunkt einer Kantenlandmarke durch die Erweiterung des detektierten Winkelintervalls bestimmt. Ist die Kantenlandmarke mit weiteren Landmarken zu Wandsegmenten verknüpft, kann der Sichtwinkel im Standpunkt der Landmarke maximal im Sichtwinkelbereich liegen, der durch die Winkel zu den verknüpften Landmarken aufgespannt wird und das detektierte Winkelintervall enthält. Das erweiterte detektierte Sichtbarkeitswinkelintervall aus Abschnitt 6.5.2 wird entsprechend eingeschränkt oder erweitert.

Verdeckungen

Eine weitere Verbesserung des Konzepts der möglichen Sichtbarkeit aus Abschnitt 6.5.2 liegt in der Erkennung von Verdeckungen von Landmarken durch Wandsegmente. Zusammen mit dem Setzen des möglichen Sichtbarkeitswinkelintervalls im Standpunkt der Landmarke ist es dadurch nicht mehr möglich, Kantenlandmarken auf Rückseiten von Wänden zu assoziieren, die sie begrenzen. Eine Landmarke durch ein Wandsegment hindurch zu observieren, ist damit nur durch die Assoziation durch Merkmalsverfolgung möglich, bei der keine Sichtbarkeitsprüfung vorgenommen wird, wodurch virtuelle Wände an Tiefensprüngen aufgelöst werden können.

Landmarkenverdeckungen werden bestimmt, indem für jede sichtbare Landmarke durch die nach Startwinkel sortierte Liste der sichtbaren Wandsegmente iteriert wird und für diejenigen Wandsegmente die Verdeckung überprüft wird, zwischen deren Start- und Endwinkel die untersuchte Landmarke gesehen wird, die eine hohe Existenzwahrscheinlichkeit besitzen, und die nicht von der untersuchten Landmarke unterstützt werden. Die Verdeckung einer Landmarke L durch das Wandsegment $w = \overline{L_{left}L_{right}}$ wird indirekt überprüft, indem zunächst getestet wird, ob die unsichere Position der Landmarke auf dem mit Unsicherheit behafteten Wandsegment liegt. Es wird dazu der probabilistische Test aus Abschnitt 7.2 verwendet. Bei diesem Test wird davon ausgegangen, dass der Sichtwinkel zur Landmarke innerhalb des Sichtwinkelbereichs zu den unterstützenden Landmarken des Wandsegments liegt, was durch die Auswahl der in Frage kommenden Wandsegmente gewährleistet ist. Liegt die Landmarke nicht auf der Wand, genügt es zu überprüfen, ob der Schnitt der Sichtlinie zur mittleren Landmarkenposition mit dem mittleren Wandsegment eine kleinere Entfernung zur Roboterpose besitzt als die mittlere Landmarkenposition, um eine Verdeckung durch das Wandsegment festzustellen.

Der probabilistische Test, ob die untersuchte Landmarke auf dem Wandsegment liegt, wird auch hier benötigt, weil Landmarken im Mittel tief initialisiert werden. Außerdem soll ein Wandsegment, das in der Tiefe unsicher ist, keine Verdeckung verursachen.

Die Überprüfung der Verdeckung von Landmarken ist teuer. Im ungünstigsten Fall muss für jede Landmarke in den Karten der Partikel die vollständige Liste der sichtbaren Wandsegmente durchsucht werden. Dieser Aufwand liegt in $O(MN^2)$. Für eine effiziente Implementierung muss daher die Anzahl der sichtbaren Wandsegmente auf eine geringe Anzahl beschränkt werden, indem beispielsweise keine Wandsegmente in der Liste enthalten sind, die von anderen Segmenten verdeckt werden.

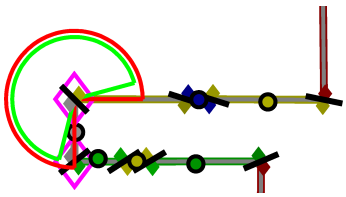

Abbildung 7.3: Beispiel einer konvexen Ecke. Das mögliche Sichtbarkeitswinkelintervall (rot) wird durch die verknüpften Wandsegmente aufgespannt. Die Landmarke wurde in einem Winkelintervall (grün) grösser als π assoziiert.

Konvexe Ecken

Spannt das mögliche Sichtbarkeitswinkelintervall im Standpunkt einer Kantenlandmarke einen Winkelbereich größer als π auf, rührt die Kante von einer konvexen Ecke in der Umgebungsstruktur her. Die Landmarke kann deshalb aus den entsprechenden Blickwinkeln auch einseitig assoziiert werden. Das Sichtbarkeitswinkelintervall wird durch die mittleren Wandsegmente festgelegt, die mit der Kantenlandmarke verknüpft sind. Damit das Sichtbarkeitswinkelintervall den tatsächlichen Winkelbereich in guter Näherung wiedergibt, muss die Tiefe der Landmarke ausreichend sicher geschätzt und ihre Positionsschätzung kartesisch parametrisiert sein.

Erwartete Merkmalsskala

Die mit einer Kantenlandmarke verknüpften Wandsegmente geben Aufschluss über die Umgebungsstrukturen, die von der Kante begrenzt werden. Bei der möglichen Sichtbarkeitsprüfung wird daher zusätzlich gefordert, dass die maximale Länge der ins Bild projizierten verknüpften mittleren Wandsegmente größer als ein Vielfaches der Standardabweichung der untersten Kantendetektionsskala ist.

7.4.3 Erwartete Sichtbarkeit

Bisher wurden nur detektierte Sichtungsorte und das detektierte Sichtbarkeitswinkelintervall im Standpunkt der Landmarke verwendet, um auf Fehldetektionen zu schliessen. Mit den sichtbaren Wandsegmenten kann die Sichtbarkeitserwartung bei Verdeckungen weiter eingeschränkt werden. Das Verfahren, um die Verdeckung einer Landmarke durch die sichtbaren Wandsegmente zu schätzen, ist analog zum Verfahren aus dem vorhergehenden Abschnitt.

7.5 Hauptorientierung der Umgebung

Eine wesentliche getroffene Annahme über die Eigenschaften der Umgebung ist die Orthogonalität bzw. Parallelität von Wänden. Wir schätzen daher aus den Wänden die Hauptorientierung der Umgebung, um beispielsweise die Observation von Wandsegmenten, die nicht zur Hauptorientierung kompatibel sind, auszuschließen.

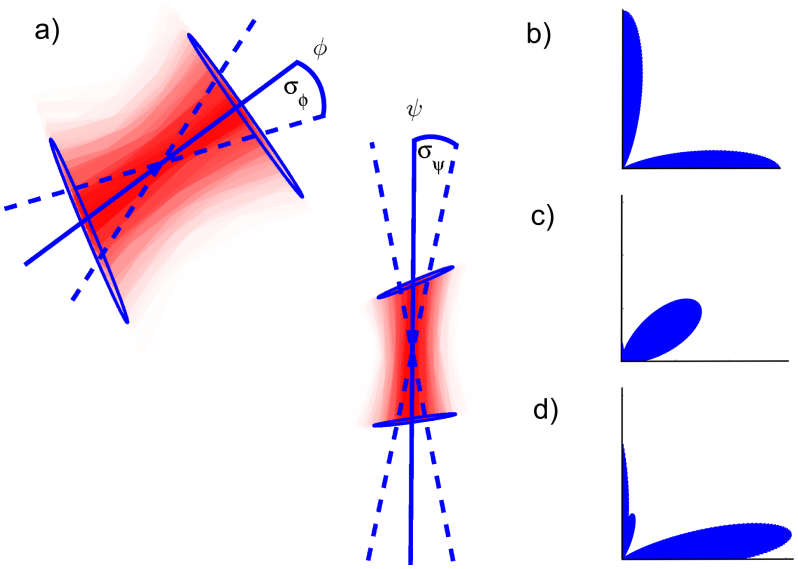

Abbildung 7.4: Illustration der Schätzung der Hauptorientierung aus Wandsegmenten. In a) sind Wandsegmente mit mittlerer Orientierung ψ bzw. ϕ und zugehörigen Standardabweichungen σ_ψ und σ_ϕ dargestellt. Diese Schätzungen werden in Orientierungshistogrammen (ψ in b, ϕ in c) visualisiert. Das Orientierungshistogramm, das durch Integration der Schätzungen für ψ und ϕ entsteht, ist in d) abgebildet.

7.5.1 Bestimmung der Hauptorientierung

Die Hauptorientierung der Karte des i-ten Partikels wird als Winkel $\psi^{[i]} \in \left[0, \frac{\pi}{2}\right)$ repräsentiert. Die tatsächliche bzw. erwartete Orientierung $\psi_{w,exp}$ eines Wandsegments in der Umgebung entspricht einem Winkel aus der Menge $\Psi^{[i]} := \{\psi^{[i]} - \frac{\pi}{2}, \psi^{[i]}, \psi^{[i]} + \frac{\pi}{2}, \psi^{[i]} + \pi\}$ der orthogonalen und parallelen Orientierungen zur Hauptorientierung.

Um die Hauptorientierung der Karte zu bestimmen, fassen wir die Orientierungen $\psi_{w_{1:W}}$ der W Wandsegmente $w_{1:W}$ in der Karte mit Existenzwahrscheinlichkeit oberhalb eines Schwellwerts als Observationen der Hauptorientierung auf. Es wird angenommen, dass die Observationen mit normalverteiltem weißem Rauschen mit Varianz σ_ψ^2 behaftet sind. Durch die Unsicherheit in den Wandsegmenten ist auch die Orientierung des Wandsegments unsicher. Eine normalverteilte Approximation $(\mu_{\psi_w}, \sigma_{\psi_w}^2)$ der Schätzung für die Orientierung des Wandsegments ψ_w ergibt sich durch Fehlerpropagation erster Ordnung aus der Schätzung des Richtungsvektors $\mu_{d_w} := d_w(\mu_{left}, \mu_{right})$ des Wandsegments $w = \overline{L_{left} L_{right}}$ und dessen Kovarianz Σ_{d_w}, die man durch Marginalisierung als Untermatrix von Σ_w in der 3. und 4. Zeile und Spalte erhält:

$$\begin{aligned}
\psi(d_w) &:= \arccos\left(\frac{d_{w,x}}{\|d_w\|}\right) \\
\mu_{\psi_w} &= arctan2(\mu_{d_w,y}, \mu_{d_w,x}) \\
\sigma_{\psi_w}^2 &= H_{d_w} \Sigma_{d_w} H_{d_w}^T \\
H_{d_w} &:= \nabla_{d_w} \psi(d_w)|_{\mu_{d_w}}
\end{aligned} \tag{7.1}$$

Gilt $\|\mu_{d_w}\| \approx 0$, kann die Orientierung des Segments nicht zuverlässig geschätzt werden, so-

dass das Wandsegment w nicht berücksichtigt wird. Mit den Observationen $z^{\psi}_{1:W} := \psi_{w_{1:W}}$ wird die Hauptorientierung durch ein rekursives Histogrammfilterverfahren [25] bestimmt. Mittelwert und Varianz in der Schätzung der Hauptorientierung werden anschließend durch Meanshift [43] im Histogramm ermittelt. Abb. 7.4 stellt ein Beispielhistogramm der Hauptorientierung für zwei Wandsegmente dar.

Das Histogramm ist diskretisiert in B Bins der Größe $\frac{\pi}{2B}$, deren Wert p_b die Wahrscheinlichkeit approximiert, dass die Hauptorientierung dem repräsentativen Winkel des Bins $\psi_b = \frac{b}{B} \cdot \frac{\pi}{2}$ entspricht. Es enthält nach Integration der k-ten Observation die Schätzung für die Hauptorientierung anhand der Wandsegmente w_1 bis w_k, d.h. für alle $b \in \{0, \ldots, B-1\}$ ist $p_{b,k} := p(\psi^{[i]} = \psi_b | z^{\psi}_{1:k})$. Die Schätzung der Hauptorientierung erfolgt rekursiv über den Index k der Wandsegmente, indem für jedes Wandsegment w_k in der Karte zu jedem Bin mit Index $0 \leq b \leq B-1$ die Differenz $\Delta\psi_b = cyc(\psi_b - \psi_{w,k}, -\frac{\pi}{4}, \frac{\pi}{4})$ zwischen Wandorientierung ψ_{w_k} und repräsentativem Winkel ψ_b des Bins bestimmt und in das Winkelintervall $\left[-\frac{\pi}{4}, \frac{\pi}{4}\right)$ abgebildet wird. Das Gewicht $w_{b,k}$ des Bins ergibt sich aus der Wahrscheinlichkeit von ψ_{w_k} unter der Erwartung, dass ψ_b der Hauptorientierung entspricht:

$$w_{b,k} := p(\psi_{w_k} | \psi^{[i]} = \psi_b) = \frac{1}{\sqrt{2\pi}\sigma_{\psi}} e^{-\frac{1}{2}\frac{\Delta\psi_b^2}{(\sigma^2_{\psi_{w,k}} + \sigma^2_{\psi})}}$$

Die Werte der Bins $p_{b,k-1}$ werden mit ihrem Gewicht $w_{b,k}$ für die Orientierung des k-ten Segments multipliziert. Anschließend werden die Werte der Bins normalisiert:

$$\forall b \in \{0, \ldots, B-1\} : p_{b,k} = \frac{w_{b,k} p_{b,k-1}}{\sum_b w_{b,k} p_{b,k-1}}$$

Aus dem Histogramm bestimmen wir die Hauptorientierung durch Meanshift. Der Algorithmus wird mit dem Winkel desjenigen Bins initialisiert, das den maximalen Wahrscheinlichkeitswert enthält. Es wird iterativ die Schätzung der Hauptorientierung verbessert, bis die Änderung zwischen den geschätzten Winkeln in den beiden letzten Iterationen geringer als ein festgelegter Schwellwert ist oder die Anzahl der Iterationen des Verfahrens überhalb einer festen Zahl maximaler Iterationen liegt. Um in der q-ten Iteration die neue Winkelschätzung ψ_q zu berechnen, werden nur solche Bins betrachtet, die innerhalb eines Winkelfensters mit Breite $\Delta\psi$ um die zuletzt geschätzte Hauptorientierung ψ_{q-1} liegen. Innerhalb des Fensters wird die Hauptorientierung durch gewichtetes Mitteln der Binwinkel bestimmt, wobei die Gewichte durch die Wahrscheinlichkeitswerte der Bins gegeben sind. Bei der Bestimmung der Bins, die innerhalb des Winkelfensters liegen, muss der zyklische Wertebereich $\left[0, \frac{\pi}{2}\right)$ der Hauptorientierung beachtet und die Winkel $\psi \pm \frac{1}{2}\Delta\psi$, die das Winkelfenster begrenzen, durch Anwendung der Funktion $cyc(\psi \pm \frac{1}{2}\Delta\psi, 0, \frac{\pi}{2})$ in den zyklischen Wertebereich abgebildet werden. Es ist klar, dass die Binwinkel aufgrund der Zyklizität des Wertebereichs nicht ohne weiteres gemittelt werden können. Daher werden anstelle der Binwinkel ψ_b die Richtungsvektoren $v_b = (\cos(4\psi_b), \sin(4\psi_b))^T$ zur Mittelung verwendet. Die neue Schätzung der Hauptorientierung ergibt sich aus dem gemittelten Richtungsvektor $\bar{v}$ durch $\psi_q = cyc(\frac{1}{4} arctan2(v), 0, \frac{\pi}{2})$. Ist die Fenstergröße kleiner als $\frac{\pi}{4}$ gewählt, kann bei der Mittelung der Richtungsvektoren keine Auslöschung auftreten. Nach Bestimmung der Hauptorientierung $\psi^{[i]}$, berechnen wir die Standardabweichung $\sigma_{\psi^{[i]}}$ von $\psi^{[i]}$ im Histogramm.

Mit einer analogen Argumentation wie bei der Bestimmung der sichtbaren Wandsegmente in Abschnitt 7.3 liegt der Laufzeitaufwand des Verfahrens im ungünstigsten Fall

in $O(MNB)$, da für jedes Partikel alle Landmarken auf Verknüpfungen untersucht werden müssen, und die Anzahl der Verknüpfungen von Landmarken durch eine Konstante abgeschätzt werden kann.

7.5.2 Verwendung für die Existenzschätzung von Wänden

Bei der Observation von Wänden wird zusätzlich die Bedingung gefordert, dass für eine positive Sichtung eines Wandsegments w die Kompatibilität mit der geschätzten Hauptorientierung $(\psi^{[i]}, \sigma^2_{\psi^{[i]}})$ gegeben ist. Die Schätzung $(\mu_{\psi_w}, \sigma^2_{\psi_w})$ der Orientierung des Wandsegments wird nach Gl. (7.1) bestimmt. Ein Innovationstest zum Konfidenzlevel α liefert das Kriterium für die Kompatibilität des Wandsegments zur Hauptorientierung:

$$\frac{\Delta\psi^2}{\sigma^2_{\psi^{[i]}} + \sigma^2_{\psi_w}} \leq \chi_{1,\alpha}. \tag{7.2}$$

Dabei muss für die Innovation $\Delta\psi$ die Zyklizität des Wertebereichs der Hauptorientierung beachtet werden. Sie ergibt sich als Differenz zwischen der beobachteten Hauptorientierung mit minimalem Abstand zu ψ_w und der erwarteten Wandsegmentorientierung ψ_w:

$$\Delta\psi = argmin_{\psi \in \Psi^{[i]}}\{|cyc(\psi - \psi_w, -\pi, \pi)|\} - \psi_w \tag{7.3}$$

7.5.3 Registrierung des Wandmodells mit der Hauptorientierung

Es wird untersucht, ob die Wandsegmente in ihrer Orientierung auf die Hauptorientierung registriert werden können, indem die Positionsschätzungen der unterstützenden Landmarken korrigiert werden. Die Korrektur wird nur dann durchgeführt, falls die Unsicherheit in der Schätzung der Hauptorientierung ausreichend gering ist, d.h. $\sigma_{\psi^{[i]}}$ unterhalb eines gewählten Schwellwerts liegt. Es wird jedes Wandsegment w korrigiert, dessen unterstützende Landmarken kartesisch parametrisiert sind und seit einer bestimmten Anzahl an Zeitschritten nicht observiert wurden, und deren Orientierungskovarianz σ_{ψ_w} nach Gl. (7.1) unterhalb eines gegebenen Schwellwerts liegt. Um die Unsicherheit in den Landmarkenpositionsschätzungen zu berücksichtigen, werden die mittleren Landmarkenpositionen analog zum EKF-Verfahren aktualisiert. Die Unsicherheit in der Schätzung wird jedoch nicht verringert, da es sich bei der Korrektur um keine Messung handelt, sondern um eine modellgetriebene Anpassung der Karte an das vorausgesetzte Umgebungsmodell. Mit der Innovation $\Delta\psi$ aus Gl. (7.3) wird zunächst die Kompatibilität des betrachteten Wandsegments zur Hauptorientierung nach Gl. (7.2) gefordert. Ist das Wandsegment w kompatibel wird für die mittleren Positionen μ_{left} und μ_{right} der unterstützenden Landmarken l_{left} und l_{right} eine Korrektur

$$\begin{aligned}
(\Delta\mu_{left}, \Delta\mu_{right})^T &:= K\Delta\psi \\
K &:= \begin{pmatrix} \Sigma_{left} & \begin{matrix} 0 & 0 \\ 0 & 0 \end{matrix} \\ \begin{matrix} 0 & 0 \\ 0 & 0 \end{matrix} & \Sigma_{right} \end{pmatrix} H^T_{left,right}(\sigma^2_{\psi^{[i]}} + \sigma^2_{\psi_w} + \sigma^2_{\psi})^{-1} \\
H_{left,right} &:= \nabla_{l_{left},l_{right}}\psi(l_{left}, l_{right})\big|_{\mu_{left},\mu_{right}}
\end{aligned}$$

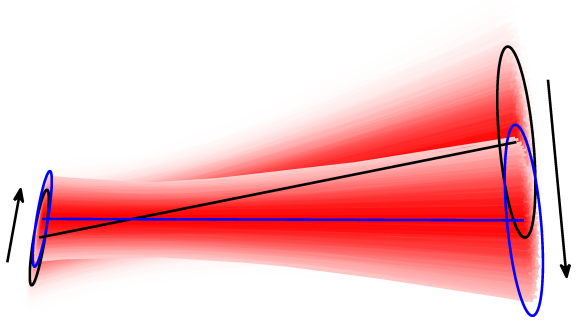

Abbildung 7.5: Illustration der Korrektur eines Wandsegments auf die Hauptorientierung ($\psi = 0, \sigma_\psi = 0.005$). Die ursprünglichen Landmarkenpositionen (schwarz) werden durch das Verfahren entsprechend der Unsicherheit in ihren Koordinaten korrigiert.

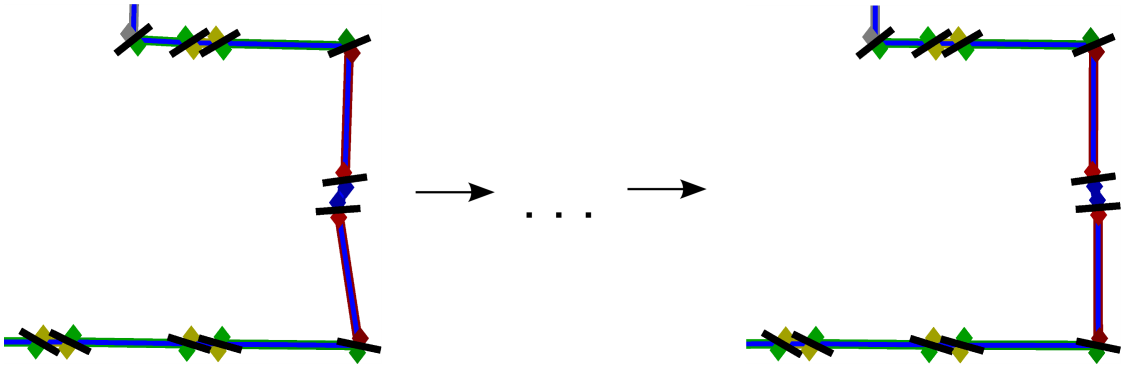

Abbildung 7.6: Beispiel für die Registrierung von Wandsegmenten auf die Hauptorientierung in der Karte. Das Verfahren wurde mehrfach angewandt.

bestimmt. Diese Korrekturen werden zu einer mittleren Korrektur für jede Landmarke akkumuliert und nach der Iteration über alle Wandsegmente auf die Landmarkenpositionsschätzungen angewandt. Abb. 7.5 und Abb. 7.6 illustrieren das Verfahren an Beispielen.

8 Verwendung in einem realen Szenario

Das Verfahren wird im folgenden Kapitel erweitert, um in einem realen Innenraumszenario evaluiert zu werden, das den getroffenen Annahmen über die Umgebung hinreichend genügt. In dieser Umgebung wird eine Kamera auf einem omnidirektional beweglichen Fahrgestell in der horizontalen Ebene bewegt, sodass Neigungswinkel und Höhe der Kamera bekannt sind. Es wird eine stark weitwinklige Kamera verwendet mit einem Sichtwinkelbereich von ca. 140° in der Horizontalen und 90° in der Vertikalen. Aus dem zweidimensionalen Kamerabild wird im Horizont ein Zeilenbild mit einem Sichtwinkelbereich von 140° extrahiert, das als Eingabe für das SLAM-Verfahren dient. Die detektierten Merkmale werden nicht helligkeitsinvariant beschrieben, sodass das Verfahren nur bei gleichbleibenden Lichtverhältnissen angewandt werden kann.

Da die Rekonstruktion von Roboterpose und Landmarkenpositionen mit reinen Winkelmessungen nur bis auf einen freien Skalenparameter möglich ist, müssen zusätzliche Informationsquellen verwendet werden, die diese Skala liefern. Es wird ein Inertialsensor benutzt, mit dem lineare Beschleunigungen in der horizontalen Ebene und Rotationsgeschwindigkeit um die vertikale Achse gemessen werden. Die Integration der Beschleunigungen zu einer Geschwindigkeitsschätzung unterliegt einer Drift, die mit einer Referenzmessung behoben werden muss. Ausserdem können in den eindimensionalen Bildern der realen Umgebung nur wenige Merkmale pro Bild extrahiert werden. Daher wird das Verfahren zusätzlich um Tiefenobservationen aus der Entfernungsschätzung zur Fußbodenkante erweitert.

8.1 Kamera- und Linsenverzerrungsmodell

Das Bild einer Kamera entsteht durch den Einfall von Lichtstrahlen auf den Bildsensor. Zunächst nehmen wir an, dass diese Abbildung rein projektiv ist. Dieses Modell wird auch als ideales Lochkameramodell bezeichnet [44]. Sei $X_c = (x, y, z)^T$ ein dreidimensionaler Punkt im lokalen Koordinatensystem der Kamera. Die Bildebene ist parallel zur x-y-Ebene des Kamerakoordinatensystems und besitzt zum Ursprung den Abstand f_l, der als Brennweite bezeichnet wird. Die normalisierten Bildkoordinaten $X_n = (\frac{x}{z}, \frac{y}{z})^T$ entstehen durch Projektion von X_c in eine imaginäre Bildebene mit $f_l = 1$. Um zu pixelwertigen Bildkoordinaten X_p zu gelangen, muss die Brennweite entsprechend gewählt und das optische Zentrum in die pixelwertige Bildmitte verschoben werden, sodass

$$X_p = f_l X_n + c = f_l \begin{pmatrix} \frac{x}{z} \\ \frac{y}{z} \end{pmatrix} + c. \tag{8.1}$$

Weitwinkelobjektive verzerren das Bild radial und tangential. Für die vorliegende Anwendung ist das Lochkameramodell hier nicht akkurat genug. Die Linsenverzerrung wird nach dem Modell von Brown [45] durch eine polynomiale Verzerrung der normalisierten

Bildkoordinaten beschrieben:

$$X_d = (1 + K_1 r^2 + K_2 r^4 + K_3 r^6) X_n + \Delta x, \text{ mit}$$
$$r := \|X_n\|$$

Der Term Δx modelliert tangentiale Verzerrungen, die wir in dieser Arbeit vernachlässigen. Die Transformation in pixelwertige Koordinaten X_p erfolgt analog zu Gl. (8.1).

Mit diesem Vorwärtsmodell können für Sichtwinkel (α, β) in Nick- und Gierwinkel und für dreidimensionale Punkte im Koordinatensystems der Kamera die korrespondierenden Bildpixelkoordinaten berechnet werden. Um bei gegebener Bildpixelkoordinate die unverzerrte, normalisierte Bildkoordinate zu bestimmen, muss das Linsenverzerrungsmodell invertiert werden. Da keine analytisch geschlossene Lösung existiert, wird für jeden Bildpixel eine numerische Lösung bestimmt und aus Gründen der Effizienz in einer vorberechneten Tabelle verwaltet.

Die Bestimmung der intrinsischen Kameraparameter f_l, c, K_1, K_2, K_3 wird als Kalibrierung bezeichnet, zu deren Bestimmung eine Reihe von Werkzeugen existiert. In dieser Arbeit wurde die Matlab Camera Calibration Toolbox [46] verwendet.

8.2 Segmentierung des Fussbodens

Eine häufige domänenspezifische Eigenschaft von Innenräumen ist, dass der Fußboden besondere Eigenschaften wie Farbe oder Textur besitzt, die ihn im Bild klar von der restlichen Umgebung trennen lässt. In der Beispielumgebung besitzt der Parkett-Fussboden eine markante gelbliche Farbe, sodass das Fussbodensegment durch Farbsegmentierung bestimmt werden kann.

Im YUV-Bild wird für jeden Pixel die Zugehörigkeit zur Farbklasse $\mathcal{C}$ des Fussbodens bestimmt. Diese Farbklasse wird durch dreidimensionale Gaussverteilungen $\{(\mu_{\mathcal{C},k}, \Sigma_{\mathcal{C},k})\}_{k=1}^{C}$ im YUV-Raum beschrieben. Sei $f(p) \in \mathbb{R}^3$ der Farbwert eines Pixels $p \in N_x \times N_y$. Die Farbklassenzugehörigkeit $c(f(p)) \in [0, 1]$ ergibt sich als maximaler Wert für $f(p)$ unter den Gaussverteilungen:

$$c(p) := \max_k \{e^{-\frac{1}{2}(f(p)-\mu_{\mathcal{C},k})^T \Sigma_{\mathcal{C},k}^{-1}(f(p)-\mu_{\mathcal{C},k})}\}$$

Da die Farbwerte der Pixel in diskreten Werten vorliegen, wird die Farbklassenzugehörigkeit aus Effizienzgründen für jede mögliche diskrete Kombination von YUV-Werten vorberechnet.

Nachdem die Farbzugehörigkeit aller Pixel im Bild bestimmt worden ist, wird ein probabilistisches Relaxationsverfahren [47] angewandt, um Farbklassenzugehörigkeit im lokalen Kontext zu verstärken bzw. abzuschwächen. Sei $l(p) \in \mathcal{K} = \{\mathcal{F}, \mathcal{R}\}$ die Klassenzugehörigkeit eines Pixels p zu den Klassen Fussboden und Nicht-Fussboden. Für jeden Pixel soll die Wahrscheinlichkeit $P(l(p) = \mathcal{F})$ bestimmt werden, dass der Pixel zur Klasse $\mathcal{F}$ des Fussbodens gehört.

Das Relaxationsverfahren wird mit der Farbklassenzugehörigkeit der Pixel als Wahrscheinlichkeit $P_0(l(p) = \mathcal{F})$ initialisiert. In einer Iteration i des Verfahrens wird für jeden Pixel eine neue Wahrscheinlichkeit $P_i(l(p) = \mathcal{F})$ berechnet, indem die Wahrscheinlichkeit der

Klassenzugehörigkeit von Pixeln in der lokalen Nachbarschaft $N(p)$ berücksichtigt wird.

$$\forall k \in \mathcal{K} : \delta P_i(l(p) = k) := \sum_{q \in N(p)} w(p,q) \left(\sum_{h \in \mathcal{K}} P(l(p) = k | l(q) = h) P_{i-1}(l(q) = h) \right)$$
$$P_i(l(p) = \mathcal{F}) = \frac{P_{i-1}(l(p) = \mathcal{F})(1 + \delta P_i(l(p) = \mathcal{F})}{\sum_{k \in \mathcal{K}} P_{i-1}(l(p) = k)(1 + \delta P_i(l(p) = k))}$$
$$\forall p \in N_x \times N_y : \sum_{q \in N(p)} w(p,q) = 1$$

Die Wahrscheinlichkeiten $P(l(p) = k | l(q) = h)$ für $k, h \in \mathcal{K}$ legen den Einfluss der Klassenzugehörigkeiten zwischen Nachbarn fest. In der vorliegenden Anwendung wurden sie als $P(l(p) = \mathcal{F} | l(q) = \mathcal{F}) = 0.95$ und $P(l(p) = \mathcal{R} | l(q) = \mathcal{R}) = 0.8$ gewählt. Es wird eine kleine Anzahl $i_{\max}$ an Iterationen durchgeführt, da die verwendete 5×5-Nachbarschaft $N(p) = \{q \in N_x \times N_y | q \neq p \wedge |q_x - p_x| \leq 2 \wedge |q_y - p_y| \leq 2\}$ eines Pixels hohen Berechnungsaufwand erfordert. Weil die Kante zwischen Fussboden- und Nicht-Fussbodenbereich von Interesse ist, wird aus dem Luminanzbild mittels Sobeloperator in x- und y-Richtung ein Kantenbild erzeugt. Bei der Berechnung der Zuwächse $\delta P_i(l(p))$ wird ein Nachbar q nur dann einbezogen, falls kein Pixel zwischen p und q liegt oder die Kantenwertigkeit des Pixels zwischen p und q gering ist. Die Gewichte müssen entsprechend normalisiert werden. Auf diese Weise wird nicht über Helligkeitskanten hinweg relaxiert.

Im nächsten Schritt wird der Fussboden als eine Menge von Zusammenhangskomponenten der als Fussboden klassifizierten Pixel $p \in \{q \in N_x \times N_y | P(l_q = \mathcal{F}) > 0.5\}$ bestimmt. Dabei sind nur solche Zusammenhangskomponenten in der Menge enthalten, die Bildpixel enthalten, deren korrespondierende Sichtlinie den Fussboden in einem Radius r um die Pose des Roboters schneidet. Die Bestimmung der Menge der Zusammenhangskomponenten erfolgt durch Tiefensuche der als Fussboden klassifizierten Punkte, indem das Bild als Graph aufgefasst wird mit der Menge der Pixel als Knoten und der direkten Nachbarschaftsbeziehungen zwischen Pixeln als Kanten. Der in das Bild projizierte Umkreis um den Roboter wird in einer festen Anzahl von Pixeln abgetastet. Die Tiefensuche wird in diesen abgetasteten Pixeln gestartet.

Anschliessend wird ein Öffnungsoperator auf die Vereinigung der Zusammenhangskomponenten angewandt, um Übergänge auf Wandbereiche aufzulösen, die fälschlicherweise als Fussboden klassifiziert wurden. Anschliessend wird erneut eine Zusammenhangskomponente in der geöffneten Menge bestimmt. Es werden schliesslich diejenigen Pixel als zum Fussboden zugehörig klassifiziert, die in den ursprünglichen Zusammenhangskomponenten enthalten sind und lokal von Pixeln in den geöffneten Zusammenhangskomponenten benachbart sind. Abb. 8.1 zeigt die Ergebnisse der einzelnen Verarbeitungsschritte an einem Beispiel.

8.3 Tiefenschätzung am Fussbodensegment

Seien Nickwinkel im folgenden mit α und Gierwinkel mit β bezeichnet. Das erzeugte Zeilenbild wird im Horizont extrahiert. Der Sichtwinkel α_{Hor} zum Horizont entspricht dem Neigungswinkel der Kamera, insofern die Kamera horizontal ausgerichtet ist. Das Zeilenbild besteht aus $N = 1024$ Pixeln, deren korrespondierende Sichtwinkel β_{Hor} durch das Kamera- und Linsenverzerrungsmodell in Abschnitt 4.3 gegeben sind. Die

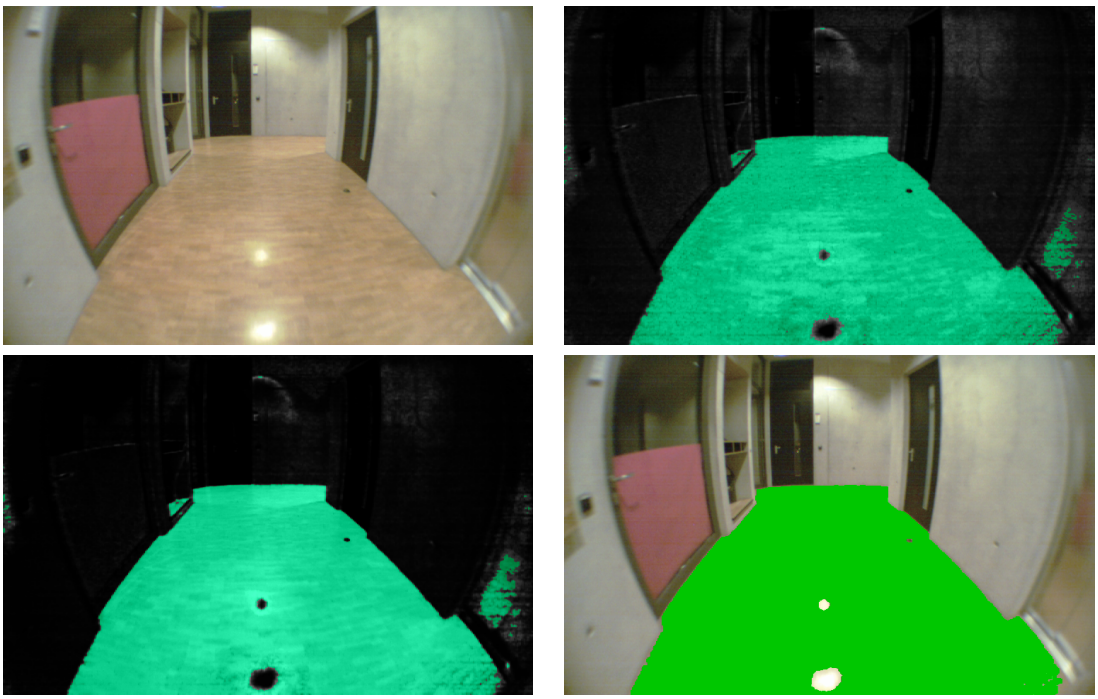

Abbildung 8.1: Beispiel für die Ergebnisse der einzelnen Verarbeitungsschritte bei der Fussbodensegmentierung. Links oben: Originalbild. Rechts oben: Pixel mit Farbzugehörigkeit über 0.5 sind umso mehr cyan, je stärker ihre Farbzugehörigkeit ist. Für Farbzugehörigkeiten unter 0.5 werden Pixel grau eingezeichnet. Die Helligkeit ist ebenfalls durch die Stärke der Farbzugehörigkeit angegeben. Links unten: Vierfach relaxiertes Bild mit analoger Färbung zum Farbzugehörigkeitsbild. Rechts unten: Fussbodensegment nach Öffnung und Abgleich der Zusammenhangskomponente.

Tiefe im Sichtwinkel β_{Hor} eines Zeilenbildpixels wird auf folgende Weise bestimmt: Die normalisierte Bildkoordinate $X_n = (tan(\beta_{Hor}), tan(\alpha_{Hor}))^T$ entspricht einer Position X_g auf der imaginären Bildebene in kamerazentrischen Weltkoordinaten. Die Gerade $\gamma : x = X_g + \lambda(0,0,1)^T$ durch diese Position verläuft entlang des Normalenvektors des Fussbodens. Durch Projektion dieser Geraden in das Bild erhält man diejenige Gerade in der Bildebene, in der im Winkel β_{Hor} Geraden observiert werden, die entlang der Fussbodennormalen verlaufen. In Abb. 8.2 ist die projektive Abbildung von vertikalen Geraden in das unverzerrte Bild skizziert.

Diese Gerade wird zum unteren Bildrand verfolgt. Wird ein als Fussboden klassifizierter Pixel gefunden, wird die Anzahl an Fussbodenpixeln mit der Anzahl an Nicht-Fussbodenpixeln unter den folgenden K Pixeln entlang der projizierten Gerade ins Verhältnis gesetzt, welches als Detektionssicherheit c_d der Tiefenschätzung verwendet wird. Da die Kamerahöhe bekannt ist, kann die Tiefe d leicht bestimmt werden, indem die Entfernung zum Schnitt der Sichtlinie zum ermittelten Pixel mit der Fussbodenebene berechnet wird. Die Varianz $\sigma_d^2 = \sigma_{d,0}^2 + \sigma_{d,dist}^2 + \sigma_{d,local}^2$ in der Tiefenmessung ergibt sich aus mehreren Komponenten, die die Unsicherheit in der Messung beeinflussen. Für alle Tiefenmessungen wird eine Grundvarianz $\sigma_{d,0}^2 = 0.1^2$ modelliert, die Fehler in den intrinsischen Parametern und unmodellierten Begebenheiten der Umgebung erfassen soll.

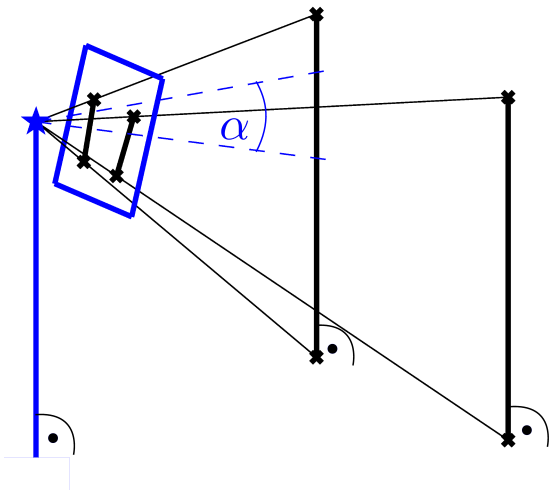

Abbildung 8.2: Skizze der projektiven Abbildung von vertikalen Geraden in das unverzerrte Kamerabild. Die Kamera befindet sich an der mit dem Stern markierten Stelle und ist mit dem Nickwinkel α geneigt. Geraden, die entlang der Fussbodennormalen verlaufen, werden auf Geraden im Bild abgebildet, die für $\alpha \neq 0$ nicht parallel sind.

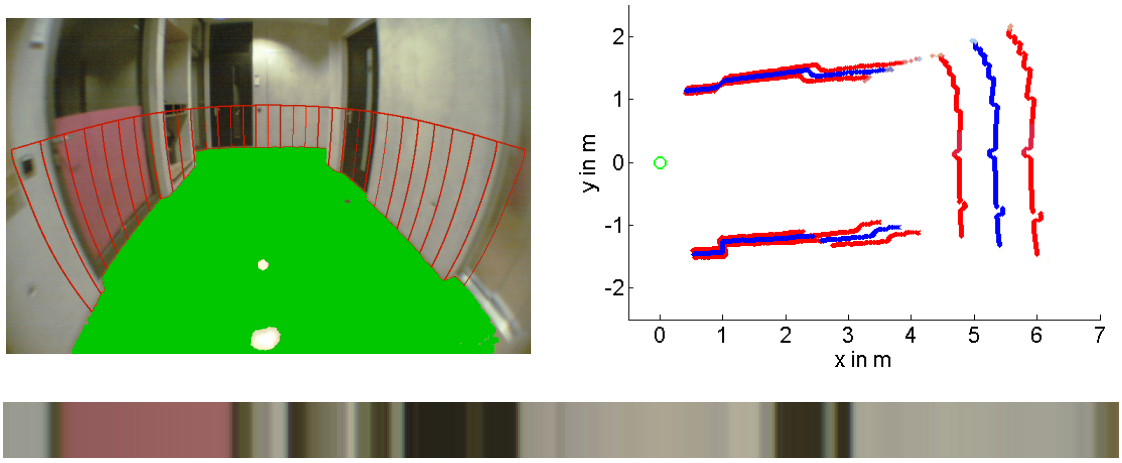

Abbildung 8.3: Beispiel für ein extrahiertes Zeilen- und Tiefenbild. Links oben: Ausgehend vom Horizont im Bild (rote horizontale Linie) werden für jeden Zeilenbildpixel vertikale Gerade im entsprechenden Sichtwinkel bis zur Fussbodenkante verfolgt. Rechts oben: Extrahierte mittlere Tiefenmessung (blau) und zugehörige Tiefenmessungen mit Standardabweichungen in jede Richtung (rot) für $\sigma_{d,0}^2 = 0$. Messungen sind umso heller, je unsicherer sie detektiert wurden. Das Koordinatensystem ist kamerazentrisch. Unten: Extrahiertes Zeilenbild.

Die Standardabweichung $\sigma_{d,dist}$ wird als mittlere Abweichung in der Distanzschätzung für $\pm 1°$ Winkelabweichung im Nickwinkel der Kamera bestimmt, um Schwankungen in diesem Winkel und pixelhafte Abweichungen der segmentierten Fussbodenkante zu modellieren. Zusätzlich wird die lokale Varianz $\sigma^2_{d,local}$ in der Distanzschätzung für benachbarte Zeilenbildpixel berücksichtigt, da an Tiefensprüngen und bei fehlerhaft segmentiertem Fussboden hohe lokale Varianz auftritt. Ist die lokale Varianz gross, wird deshalb auch die Detektionssicherheit für die Schätzung verringert. Abb. 8.3 zeigt Horizont, projizierte vertikale Geraden und extrahierte Tiefenmessung an einem Beispiel.

Tiefenmessungen überhalb einer maximalen Entfernung sind unzuverlässig und werden entsprechend markiert. Analog wird die Messung als unterhalb des minimalen Entfernungsbereich markiert, falls bis zum unteren Bildrand entlang der projizierten vertikalen Gerade kein als Fussboden klassifizierter Pixel gefunden werden konnte.

In der Implementation werden die projizierten vertikalen Geraden für jeden Zeilenbildpixel abgetastet und aufeinanderfolgende Pixel in einer verketteten Liste gespeichert.

8.4 Extraktion eines Zeilenbilds

Die YUV-Farbwerte der Zeilenbildpixel werden ebenfalls entlang der projizierten vertikalen Geraden bestimmt. Ziel ist es, die signifikante Wandfarbe eines Pixels zu bestimmen. Daher wird für jeden Zeilenbildpixel der Bereich entlang der Geraden zwischen Horizont und Fussbodenkante betrachtet, falls für den Pixel eine zuverlässige ($c_d > 0$) Tiefenschätzung zur Verfügung steht. Das untere Viertel des Bereichs wird für die Bestimmung der Wandfarbe ausgelassen, um robust gegenüber Störungen in der Fussbodensegmentierung zu sein. Ist die Tiefe nicht bekannt, wird der Bereich auf eine minimale Größe gesetzt, die dem Bereich zwischen Horizont und einer maximal detektierbaren Tiefe entspricht. Der Farbwert des Zeilenbildpixels wird im ermittelten Bereich durch ein Meanshift-Verfahren [43] bestimmt, um die signifikante Wandfarbe zu erhalten und Ausreisser auszuschliessen. Der Algorithmus wird mit den mittleren Farbwerten des Bereichs initialisiert. Das Verfahren wird iteriert, bis eine maximale Anzahl an Iterationen erreicht ist, oder weniger als 75% der Pixel im betrachteten Bereich verwendet werden können. In diesem Fall wird der Mittelwert aus der letzten Iteration als Farbwert zurückgeliefert. Abb. 8.3 enthält ein Beispiel für ein extrahiertes Zeilenbild.

8.5 Verwendung von Tiefenmessungen im SLAM-Verfahren

Das bisherige SLAM-Verfahren basiert auf reinen Winkelobservationen von visuellen Landmarken. Da Tiefenobservationen am Fussbodensegment nicht für jeden Zeilenbildpixel zur Verfügung stehen und in ihrer maximalen Messentfernung begrenzt sind, werden sie ergänzend verwendet. Landmarken sollen also sowohl rein durch Winkel als auch durch Winkel und Tiefe observiert werden können. Diese Methode besitzt den Vorteil, dass Landmarken, für die keine Tiefenobservationen zur Verfügung stehen, als Indikatoren für die Orientierung des Roboters dienen können und bereits durch Bewegungsparallaxe ihre Tiefe bestimmt werden kann. Ausserdem können Merkmale ohne Tiefeninformationen mit Landmarken reassoziiert werden, was insbesondere für das Schliessen von Schleifen von Vorteil ist. Wird eine Landmarke im Ort z_t observiert, wird ihr die Tiefenobservation (z^d_t, Q^d_t, c^d_t) des nächsten korrespondierenden Pixels im Zeilenbild zugeordnet.

8.5.1 Erweitertes Landmarkenobservationsmodell

Ist die Detektionssicherheit c_t^d der Tiefenobservation überhalb eines Schwellwertes, wird die Tiefeninformation im Observationsmodell der Landmarke berücksichtigt. Das augmentierte Observationsmodell

$$\underbrace{\begin{pmatrix} z_t \\ z_t^d \end{pmatrix}}_{=:\widehat{z}_t} = \underbrace{\begin{pmatrix} h(s_t, l) \\ h^d(s_t, l) \end{pmatrix}}_{=:\widehat{h}(s_t,l)} + \delta_t, \delta_t \sim \mathcal{N}\left(0, \underbrace{\begin{pmatrix} Q_t & 0 \\ 0 & Q_t^d \end{pmatrix}}_{=:\widehat{Q}_t}\right)$$
$$h^d(s_t, l) := \left\| l - (x_t, y_t)^T \right\|$$

erklärt Observationen von Bildkoordinaten und Tiefe als normalverteilt verrauschte Erwartungen, die durch h und h^d in der Pose s_t des Roboters und der Landmarkenposition l gegeben sind. Das augmentierte Observationsmodell wird verwendet, um die Posenkorrektur durchzuführen, die Observationswahrscheinlichkeit der Landmarke bei der Partikelgewichtung zu berechnen und die Landmarkenpositionsschätzung zu korrigieren.

8.5.2 Tiefeninitialisierung von Landmarken

Landmarken werden bei ihrer ersten Sichtung weiterhin in inverser Tiefe initialisiert. Ist die Tiefenobservation zuverlässig, werden Mittelwert und Varianz der inversen Tiefe der Landmarke mit der observierten Tiefe initialisiert. Die Schätzung (ρ, σ_ρ^2) in inverser Tiefe ergibt sich aus der Tiefenobservation (z_t^d, Q_t^d) durch Fehlerpropagation erster Ordnung:

$$\rho := \frac{1}{z_t^d}$$
$$\sigma_\rho^2 := \frac{Q_t^d}{(z_t^d)^4}$$

8.5.3 Erweiterte Datenassoziation

Steht für eine Landmarkenobservation eine zuverlässige Tiefenobservation zur Verfügung, wird für die Überprüfung und Berechnung der Kompatibilität bei der daten- und modellgetriebenen Datenassoziation der Innovationstest in Gl. (6.5) mit Innovation und Kovarianz

$$\Delta z_t = \widehat{z}_t - \widehat{h}(s_t, l_j) \text{ und}$$
$$C_z = H_s R_t^{[i]} H_s^T + H_l \Sigma_{j,t-1}^{[i]} H_l^T + Q_t, \text{ wobei}$$
$$H_s := \nabla_{s_t} \widehat{h}(s_t, l_j)\Big|_{\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}}$$
$$H_l := \nabla_{l_j} \widehat{h}(s_t, l_j)\Big|_{\hat{s}_t^{[i]}, \mu_{j,t-1}^{[i]}}$$

berechnet. Die Kompatibilitäten von reinen Winkelobservationen sind nicht direkt vergleichbar mit den Kompatibilitäten von Winkel- und Tiefenobservationen, was eine Präferenz für Assoziationen von Landmarken mit Merkmalen zur Folge hätte, für die keine Tiefeninformationen zur Verfügung stehen. Daher wird die Kompatibilität von Merkmalen zu

Landmarken um 1 verringert, deren Tiefe nicht zuverlässig bestimmt werden konnte. Das entspricht einer Abweichung in der Tiefe um eine Standardabweichung.

Falls die Tiefenmessung für ein Merkmal ausserhalb des maximalen Entfernungsbereichs liegt, kann das Merkmal nicht mit Landmarken assoziiert werden, deren mittlere Distanz zur Roboterpose unterhalb eines Schwellwerts liegt. Analog können Merkmale mit Tiefe unterhalb des minimalen Entferungsbereichs nicht mit Landmarken assoziiert werden, die weit entfernt sind.

8.5.4 Erweiterte Existenzschätzung von Wänden

Forderung von Tiefenkompatibilität

Bei der Aktualisierung des Wandmodells werden dann positive Sichtungen von Wandsegmenten erzeugt, falls der Bereich zwischen den untersuchten Landmarken nicht nur im Bild zum interpolierten Deskriptor der Landmarken kompatibel ist, sondern auch in den Tiefenobservationen zum untersuchten Wandsegment.

Sei $w = \overline{L_{left}L_{right}}$ das untersuchte Wandsegment. Für jeden Sichtwinkel ϕ im Bereich zwischen den Landmarken, in dem die Kompatibilität im Bild überprüft wird, wird eine normalverteilte Schätzung $(\mu_\delta, \sigma_\delta)^2$ der Entfernung δ zur Wand aus dem Schnittpunkt des Wandsegments mit der Sichtlinie ermittelt, falls eine zuverlässige Tiefenobservation (d, σ_d^2) zur Verfügung steht:

$$\begin{aligned}
m_w &:= m_w(l_{left}, l_{right}) \\
d_w &:= d_w(l_{left}, l_{right}) \\
\delta(s_t, l_{left}, l_{right}, \phi') &:= \frac{(d_{w,y}(m_{w,x} - x_t) - d_{w,x}(m_{w,y} - y_t))}{(\cos(\theta_t + \phi')d_{w,y} - d_{w,x}\sin(\theta_t + \phi'))} \\
\mu_\delta &= \delta(s_t^{[i]}, \mu_{left}, \mu_{right}, \phi) \\
\Sigma_{left,right} &:= \begin{pmatrix} \Sigma_{left} & \begin{matrix} 0 & 0 \\ 0 & 0 \end{matrix} \\ \begin{matrix} 0 & 0 \\ 0 & 0 \end{matrix} & \Sigma_{right} \end{pmatrix} \\
\sigma_\delta^2 &= H_l \Sigma_{left,right} H_l^T \\
H_l &:= \nabla_{(l_{left}, l_{right})^T} \delta(s_t, l_{left}, l_{right}, \phi')\Big|_{s_t^{[i]}, \mu_{left}, \mu_{right}, \phi}
\end{aligned} \tag{8.2}$$

mit der Pose $s_t^{[i]} = (x_t, y_t, \theta_t)^T$ des i-ten Partikels. Die Kompatibilität von Tiefenobservation zur Wandtiefe wird auch hier mit einem Innovationstest (Gl. (6.5)) mit Innovation $\Delta z = d - \mu_\delta$ und Kovarianz $C_z = \sigma_d^2 + \sigma_\delta^2$ überprüft.

Erweiterung von Randzeigern um Tiefe

Das Konzept der Randzeiger wird ebenfalls erweitert, indem für die Randzeigerlandmarke eine normalverteilte Schätzung $(\mu_{\psi,t}, \sigma_{\psi,t}^2)$ der Wandorientierung ψ am Bildrand unterhalten wird. Es werden zuverlässige Tiefenobservationen (d, σ_d^2) am Bildrand rekursiv in die Schätzung mit einem EKF-Verfahren integriert. Die observierte Tiefe am Bildrand wird als Messung des Schnittpunkts der Sichtlinie zum Bildrand mit der Geraden aufgefasst, die durch den Ort der Randzeigerlandmarke L und die Richtung der geschätzten

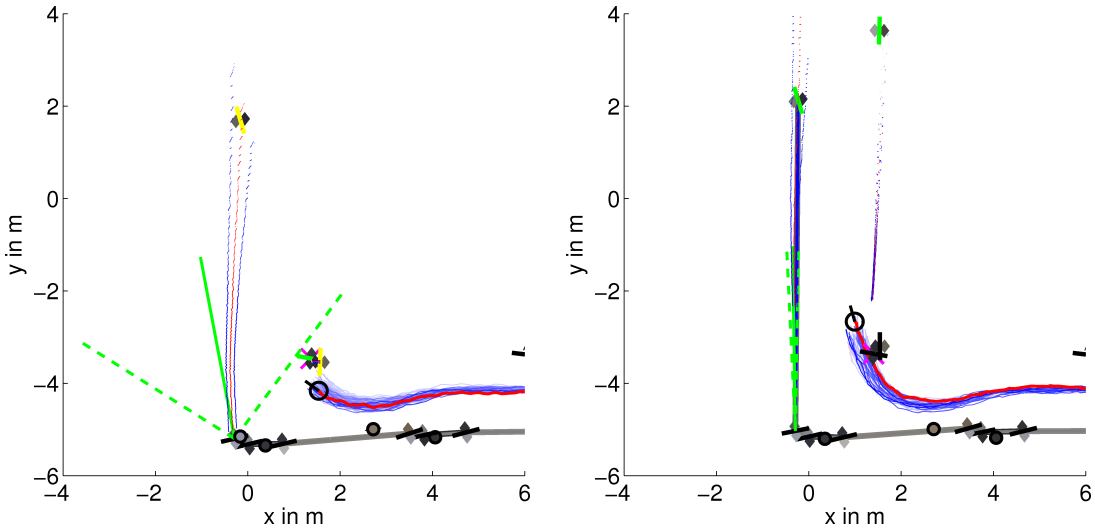

Abbildung 8.4: Beispiel für die Schätzung des Wandsegments am Bildrand. Das Wandsegment wird ausgehend von einer neuen Randzeigerlandmarke in seiner Orientierung (grüner Indikator mit σ-Umgebung) unsicher initialisiert (links). Die Schätzung der Orientierung wird rekursiv aktualisiert und ermöglicht es, ein Wandsegment zu einer unbeobachteten Landmarke einzufügen, das durch die Tiefenobservationen zwischen den Landmarken gestützt wird (rechts). Tiefenobservationen werden mit roten Mittelwerten und blauen Standardabweichungen ohne Grundunsicherheit dargestellt.

Wandorientierung parametrisiert ist. Sei ϕ der Sichtwinkel zum Bildrand. Die Sichtlinie und die Gerade des Wandsegments am Bildrand sind in der Pose $s_t = (x_t, y_t, \theta_t)^T$ des Roboters durch

$$\gamma_\phi : x = \begin{pmatrix} x_t \\ y_t \end{pmatrix} + \lambda_\phi \begin{pmatrix} \cos(\theta_t + \phi) \\ \sin(\theta_t + \phi) \end{pmatrix} \text{ und}$$
$$\gamma_\psi : x = l + \lambda_\psi \begin{pmatrix} \cos(\psi) \\ \sin(\psi) \end{pmatrix}$$

gegeben. Schnitt der Geraden liefert $\lambda_\psi(s_t, \phi, l, \psi)$ in Abhängigkeit von der Pose s_t, dem Sichtwinkel ϕ zum Bildrand, der Landmarkenposition l und der Wandorientierung ψ am Bildrand. Da der Richtungsvektor der Sichtlinie die Norm 1 besitzt, kann die normalverteilte Schätzung $(\mu_\delta, \sigma_\delta^2)$ in der erwarteten Tiefe des Schnittpunkts aus λ_ψ bestimmt werden:

$$\begin{aligned} \mu_\delta &:= \lambda_\psi(s_t, \phi, \mu_l, \psi) \\ \sigma_\delta^2 &:= H_l \Sigma_l H_l^T + H_\psi \sigma_\psi^2 H_\psi^T \\ H_l &:= \nabla_l \ \lambda_\psi(s_t, \phi, l, \psi)|_{\mu_l, \mu_\psi} \\ H_\psi &:= \nabla_\psi \ \lambda_\psi(s_t, \phi, l, \psi)|_{\mu_l, \mu_\psi} \end{aligned}$$

Die Kompatibilität der Tiefenobservation zur Tiefe zum Wandsegment am Bildrand wird mit einem Innovationstest mit Innovation $\Delta z = d - \mu_\delta$ und Kovarianz $C_z = \sigma_d^2 + \sigma_\delta^2$ überprüft. Ist die Tiefenobservation nicht kompatibel zur Wandorientierung, wird der Randzeiger zurückgesetzt.

Zur Initialisierung wird die globale Orientierung der Differenz $v(s_t, \phi, l, d') := p_{d'} - l$ zwischen dem kartesischen Endpunkt der Tiefenobservation und der mittleren Randzeigerlandmarkenposition verwendet:

$$\begin{aligned}
\psi_{init}(s_t, \phi, l, d') &:= \arccos\left(\frac{v_x(s_t, \phi, l, d')}{\|v(s_t, \phi, l, d')\|}\right) \\
\mu_\psi &:= arctan2(v_y(s_t, \phi, \mu_l, d), v_x(s_t, \phi, \mu_l, d)) \\
\sigma_\psi^2 &:= H_d \sigma_d^2 H_d^T \\
H_d &:= \nabla_{d'}\ \psi_{init}(s_t, \phi, l, d')\big|_{s_t, \phi, \mu_l, d}
\end{aligned}$$

Die Orientierungsschätzung wird nur mit zuverlässigen Tiefenobservationen initialisiert, falls die mittlere Distanz zwischen Landmarkenposition und kartesischem Endpunkt der Tiefenobservation, $\|v(s_t, \phi, \mu_l, d)\|$, signifikant gross ist, damit die Orientierung zwischen den Positionen zuverlässig ist. Abb. 8.4 zeigt ein Beispiel für die Schätzung der Wandsegmentorientierung am Bildrand.

8.5.5 Observation und Korrektur von Wänden durch Tiefe

In einer reduzierten Auflösung des Tiefenbilds werden Tiefenobservationen $\mathcal{D} = \{D_k = (d_k, \sigma_{d,k}^2, c_{d,k})\}_{k=1}^K$ dazu verwendet, die sichtbaren Wandsegmente im korrespondierenden Sichtwinkel ϕ_k zu korrigieren und eine Observationswahrscheinlichkeit der gemessenen Tiefe zu berechnen. Es können mehrere Wandsegmente zur Observation in einem Pixel kompatibel sein. Daher wird für jedes Pixel die mittlere Observationswahrscheinlichkeit für die J observierten Wandsegmente durch Ziehen der J-ten Wurzel aus dem Produkt der einzelnen Observationswahrscheinlichkeiten berechnet. Damit die Gesamtwahrscheinlichkeit der Wandobservationen dem Gewicht einer Landmarkenobservation entspricht, wird das Produkt der mittleren Pixelobservationswahrscheinlichkeiten durch Ziehen der K-ten Wurzel diskontiert. Das Partikel wird zusätzlich mit dieser Observationswahrscheinlichkeit gewichtet. Die Observation und Korrektur der Wandsegmente erfolgt nach der Existenzschätzung der Wandsegmente.

Für jeden Pixel k in der reduzierten Auflösung wird für jedes sichtbare, existierende Wandsegment $w = \overline{L_{left} L_{right}}$ zunächst überprüft, ob das Winkelintervall, in dem w sichtbar ist, grösser als ein Schwellwert ist, da ansonsten geringfügige Fehler in der Orientierung erhebliche Fehler in der Tiefe bewirken. Zusätzlich werden Wandsegmente nur weiter betrachtet, falls sie im Sichtwinkel ϕ_k nicht an ihrem Rand beobachtet werden, da Tiefenmessungen an unterstützenden Landmarken bereits bei der Observation und Aktualisierung von Landmarken berücksichtigt werden. Zunächst wird die Kompatibilität der Wand mit der Tiefenobservation D_k im Sichtwinkel ϕ_k mit der Methode aus dem vorherigen Abschnitt 8.5.4 überprüft. Ist das Wandsegment mit der Observation kompatibel, werden die unterstützenden Landmarken in einem EKF-Korrekturschritt aktualisiert:

$$\begin{aligned}
K &:= \Sigma_{left,right,k-1} H_l^T (\sigma_\delta^2 + \sigma_{d,k}^2)^{-1} \\
\begin{pmatrix} \mu_{left,k} \\ \mu_{right,k} \end{pmatrix} &= \begin{pmatrix} \mu_{left,k-1} \\ \mu_{right,k-1} \end{pmatrix} + K(d_k - \mu_\delta) \\
\Sigma_{left,right,k} &= (I - KH_l)\Sigma_{left,right,k-1}
\end{aligned}$$

mit den Definitionen aus Gl. (8.2). Die entstehenden Korrelationen der unterstützenden Landmarken werden vernachlässigt, sodass sich die Kovarianzen der unterstützenden

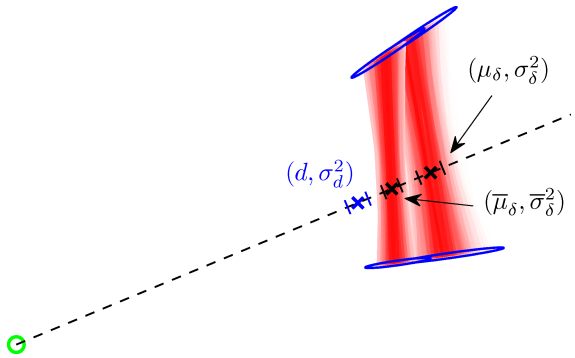

Abbildung 8.5: Beispiel für die Korrektur eines Wandsegments anhand einer Tiefenmessung (d, σ_d^2). Das Wandsegment wird durch ein EKF-Verfahren entlang der Sichtlinie korrigiert. Im Vergleich zur Schätzung $(\mu_\delta, \sigma_\delta^2)$ des Wandsegmentschnitts mit der Sichtlinie vor der Korrektur ist die Unsicherheit in $(\overline{\mu}_\delta, \overline{\sigma}_\delta^2)$ nach der Korrektur der Landmarkenpositionsschätzungen verringert. Die Tiefenschätzungen sind mit ihrer σ-Umgebung dargestellt.

Landmarken aus den entsprechenden Untermatrizen von $\Sigma_{left,right,k}$ ergeben. Abb. 8.5 enthält ein Beispiel für die Korrektur eines Wandsegments anhand einer Tiefenmessung.

Die Observationswahrscheinlichkeit $p(d_k|s_t, w)$ der Tiefe des Pixels k für das Wandsegment w ergibt sich aus

$$p(d_k|s_t, w) \approx \mathcal{N}(d_k; \mu_\delta, \sigma_\delta^2 + \sigma_{d,k}^2)$$

Der partikelspezifische Index i wurde aus Gründen der Übersichtlichkeit weggelassen.

Es ist klar, dass diese Methode heuristisch ist, da vor allem die Unabhängigkeit benachbarter Tiefenmessungen einer Wand nicht gegeben ist. Mit einer angemessenen Auflösungsreduktion kann diesem Problem begegnet werden.

8.5.6 Extraktion und Verwendung von Tiefenmerkmalen

Das Tiefenbild liefert ergänzende Informationen zu den visuellen Merkmalen. Zum einen können Tiefensprünge erkannt werden, sodass es möglich ist, Kantenlandmarken nur einseitig zu assoziieren und das Einfügen virtueller Landmarken und Wandsegmente zu verhindern. Umgebungsstrukturen können konvexe oder konkave Ecken enthalten, in denen visuell nicht unterscheidbare Wandsegmente aufeinandertreffen. Die Konvexität bzw. Konkavität einer Ecke ist aber ein salientes Merkmal im Tiefenbild. Es werden daher interessante Stellen in Tiefensprüngen und konvexen bzw. konkaven Ecken detektiert. Diese interessanten Stellen werden anschließend mit visuellen Kantenmerkmalen fusioniert und visuell in gleicher Weise wie Kanten beschrieben. Abb. 8.6 zeigt Beispiele für den Extraktionsprozess. Eine detaillierte Beschreibung der Extraktion findet sich im Anhang B zu dieser Arbeit.

Tiefenmerkmale und fusionierte Merkmale können bis auf wenige Besonderheiten wie visuelle Merkmale im SLAM-Verfahren verarbeitet werden.

- Die Tiefe der Merkmale wird während der Extraktion bestimmt und muss nicht aus dem Tiefenbild extrahiert werden.
- Bei der Datenassoziation wird für Landmarken gespeichert, ob sie mit Tiefensprungmerkmalen assoziiert wurden. Diese Landmarken können in folgenden Zeitschritten

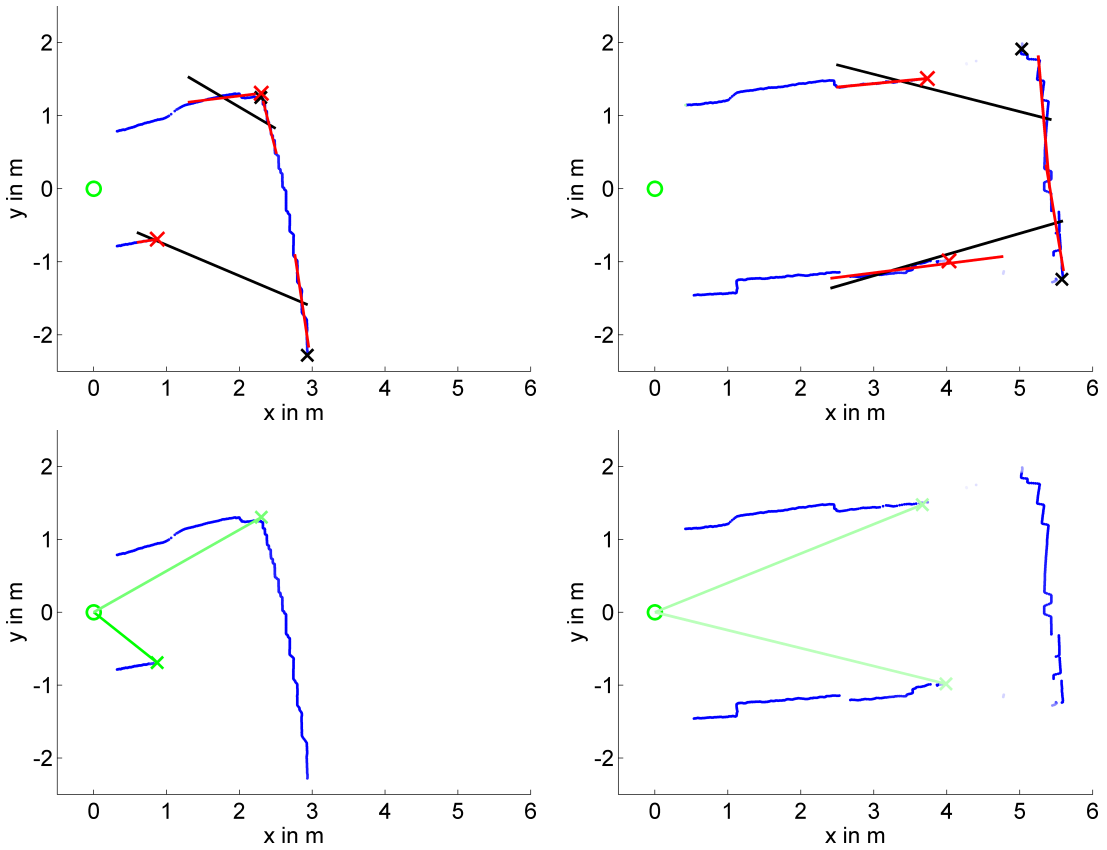

Abbildung 8.6: Beispiele für die Extraktion von Tiefenmerkmalen. Oben: Durch eine Teilmenge der Tiefenmessungen werden Geraden (schwarz) approximiert, zu denen Punkte mit maximaler Entfernung als Spaltpunkte (schwarze Kreuze) bestimmt werden. Die Punktmenge wird am Spaltpunkt in zwei Punktmengen getrennt, durch die Geraden (rot) approximiert werden. Eine Reihe von Kriterien führt zu Kandidatenstellen für Tiefenmerkmale (rote Kreuze). Unten: Ein detektiertes Tiefenmerkmal (grünes Kreuz) wird umso intensiver gefärbt, desto höher seine Detektionssicherheit ist. Die Koordinatensysteme sind egozentrisch.

nur mit Tiefensprungmerkmalen derselben Seitigkeit oder konvexen Tiefenkanten assoziiert werden, bis die Landmarke mit Hilfe der verknüpften Wandsegmente als konvex klassifiziert wurde. Die Kompatibilität wird analog zu konvexen Kantenlandmarken nur in der nichtoffenen Seite eines Tiefensprungs berechnet und überprüft.

8.6 Bewegungsschätzung

Für die Bewegungsschätzung stehen weder Kontrolleingaben noch Odometrie zur Verfügung. Stattdessen verfügt der Roboter über einen Inertialsensor, der lineare Beschleunigungen in der horizontalen Ebene und vertikale Drehrate misst. Die Integration der linearen Beschleunigungen zu einer Geschwindigkeitsschätzung unterliegt einer Drift, die mit einer zusätzlichen Referenzmessung behoben wird. Dazu wird der Versatz zwischen zeitlich aufeinanderfolgenden Tiefenbildern durch Scanmatching ermittelt.

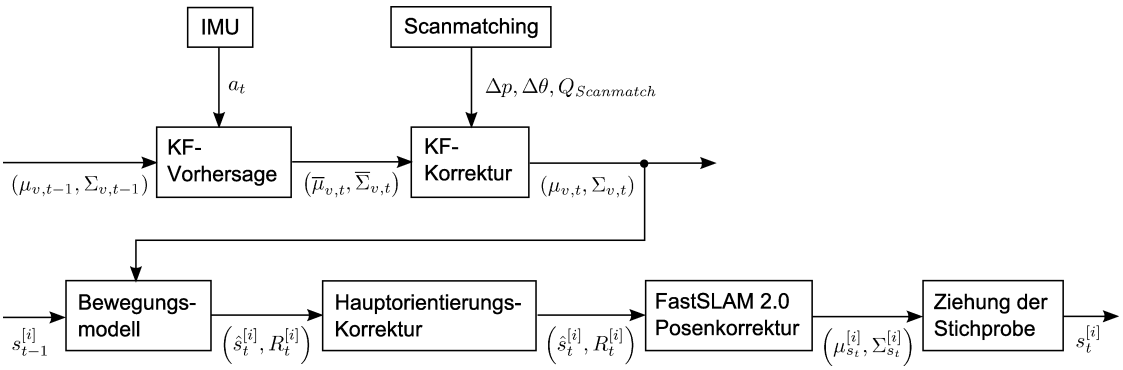

Abbildung 8.7: Schematische Darstellung der Bewegungs- und Posenschätzung

Die Orthogonalität und Parallelität der Umgebung ist in Tiefenbildern als Hauptorientierung von geradlinigien Segmenten observierbar. Durch die Modellierung von Wänden in der Karte ist die Hauptorientierung der Umgebung in guter Näherung bekannt, sodass es nahe liegt, die initialie Posenschätzung der Partikel derart anzupassen, dass die Orientierungen der Wandsegmente im Tiefenbild der Hauptorientierung in der Karte entsprechen.

Abb. 8.7 gibt einen Überblick über die einzelnen Komponenten der Bewegungs- und Posenschätzung.

8.6.1 Bewegungsinformation aus einem Inertialsensor

Ein Inertialsensor liefert Informationen über Lage und Bewegung des Sensors im Raum. Der Roboter bewegt sich ausschliesslich in der horizontalen Ebene, sodass Messungen der Drehrate um die vertikale Achse und lineare Beschleunigungen in der Horizontalen als Bewegungsinformationen interpretiert werden. Die linearen Beschleunigungssensoren des Inertialsensors messen neben den Beschleunigungen, die durch die Bewegung des Sensors verursacht werden, auch Komponenten der Erdgravitation aufgrund von geringfügigen Abweichungen von der horizontalen Lage. Da die Beschleunigungen zu einer Geschwindigkeitsschätzung integriert werden müssen, wirken sich bereits geringe Abweichungen zu einer erheblichen Drift in der Geschwindigkeit aus. In einer initialen Kalibrierungsphase wird daher der Betrag der Erdgravitation und die Lage des Sensors bestimmt, sodass die Messwerte in der linearen Beschleunigung von den Komponenten der Erdgravitation bereinigt werden können.

8.6.2 Bewegungsinformation aus Tiefenmessungen

Aus den Tiefenobservationen in aufeinanderfolgenden Zeitschritten wird die Bewegung des Roboters durch Scanmatching geschätzt. Seien $s_t = (x_t, y_t, \theta_t)^T$ und $s_{t-1} = (x_{t-1}, y_{t-1}, \theta_{t-1})^T$ die Posen des Roboters zu den Zeitpunkten t und $t-1$, sodass s_t aus s_{t-1} durch egozentrische Translation um Δp und anschließende Rotation um $\Delta\theta$ hervorgeht, d.h. $\theta_t = \theta_{t-1} + \Delta\theta$ und $(x_t, y_t)^T = (x_{t-1}, y_{t-1})^T + R(\theta_{t-1})\Delta p$. In den Zeitpunkten t und $t-1$ wird ein Punkt mit globalen Koordinaten p_g im Tiefenbild an den

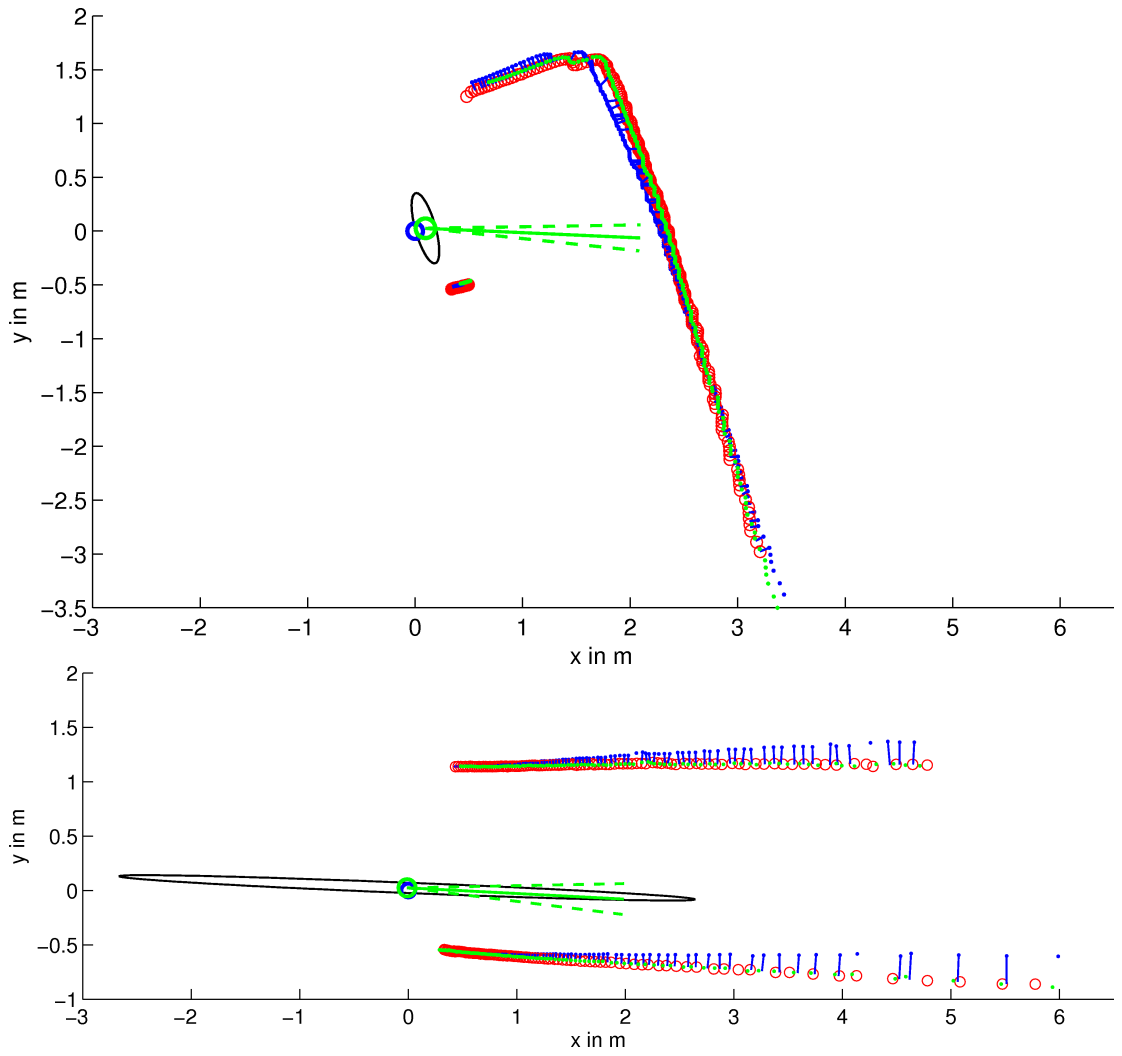

Abbildung 8.8: Ergebnisse des Scanmatching in zwei Beispielen. Der Versatz zwischen den Posen im letzten (blauer Kreis) und aktuellen Zeitschritt (grüner Kreis mit Orientierungsindikator) korrespondiert zur Transformation, die die Tiefenmessungen des aktuellen Zeitschritts (blaue Punkte) in die Messungen des letzten Zeitschritts (rote Kreise) überführt. Zu den aktuellen Messungen werden Projektionen auf Geraden durch die nächsten Nachbarn in der Punktemenge des letzten Zeitschritts bestimmt. Die Endpunkte der blauen Linien geben die projizierten Punkte in der ersten Iteration an. Das Verfahren wird bis zur Konvergenz oder einer maximalen Anzahl an Iterationen wiederholt. Die mit dem Ergebnis transformierten Punkte im aktuellen Zeitschritt werden als grüne Punkte dargestellt. Die Schätzung für die Kovarianz im ermittelten Versatz wird durch die 2σ-Umgebung der Translation (schwarze Ellipse) und durch die 2σ-Umgebung der Orientierungsänderung (grün gestrichelte Linien) visualisiert. Entlang des Korridors in der unteren Abbildung ist der Versatz nicht observierbar. Die Kovarianz bildet diese Unbestimmtheit angemessen ab.

kartesischen Positionen q_t und q_{t-1} beobachtet:

$$p_g = (x_{t-1}, y_{t-1})^T + R(\theta_{t-1})q_{t-1} \text{ und}$$
$$p_g = (x_t, y_t)^T + R(\theta_t)q_t$$

Durch Gleichsetzen und Umformen erhält man

$$\begin{aligned}(x_{t-1}, y_{t-1})^T + R(\theta_{t-1})q_{t-1} &= (x_t, y_t)^T + R(\theta_t)q_t \\ &= (x_{t-1}, y_{t-1})^T + R(\theta_{t-1})\Delta p + R(\theta_{t-1} + \Delta\theta)q_t \\ &= (x_{t-1}, y_{t-1})^T + R(\theta_{t-1})(R(\Delta\theta)q_t + \Delta p)\end{aligned}$$

und somit $q_{t-1} = R(\Delta\theta)q_t + \Delta p$.

Die Tiefenbilder werden in kartesische Punktmengen $\mathcal{Q}_{t-1} = \{q_{t-1,k}\}_{k=1}^K$ und $\mathcal{Q}_t = \{q_{t,k}\}_{k=1}^K$ transformiert, in denen die Anordnung nach Sichtwinkel erhalten wird. In einem ICP-Verfahren [48] (aus dem engl. Iterative Closest Points) werden Rotation $R := R(\Delta\theta)$ und Translation Δp bestimmt, die den quadratischen Registrierungsfehler

$$E(R, \Delta p) = \frac{1}{K}\sum_{k=1}^{K} \|Rq_{t,k} + \Delta p - \Pi(Rq_{t,k} + \Delta p, \mathcal{Q}_{t-1})\|^2 \tag{8.3}$$

zwischen korrespondierenden Punkten in den beiden Punktmengen lokal minimieren. Die Funktion $\Pi(q, \mathcal{Q})$ liefert eine Position, die basierend auf der Punktmenge $\mathcal{Q}$ zum Punkt q korrespondiert. Da Tiefenobservationen augrund der diskreten Abtastung in unterschiedlichen Posen nicht denselben Punkten im globalen Koordinatensystem entsprechen, wird als Funktion Π eine Punkt-Gerade-Metrik verwendet mit der Annahme, dass die Punktmessungen an geraden Segmenten in der Umgebung erfolgen.

Wurde q mit hoher Detektionssicherheit beobachtet, wird in $\mathcal{Q}$ ein nächster Nachbar q'_k bestimmt, der ebenfalls hohe Detektionssicherheit besitzt. Die Distanz zwischen q und q'_k darf eine maximale Entfernung nicht überschreiten. Der Punkt q wird auf die Geraden zwischen q'_k und dessen direkte Nachbarn $q'_{k\pm1}$ projiziert, falls diese nicht weiter als eine maximale Distanz von q'_k entfernt sind. Dabei werden nur solche Punkte betrachtet, deren Detektionssicherheit überhalb eines Schwellwerts liegt. Liegt die Projektion von q zwischen den Stützstellen einer der Geraden, liefert die Funktion Π für q diesen projizierten Punkt, falls die Distanz zwischen q und der Projektion genügend klein ist. Ein Punkt, dessen Projektion bestimmt werden konnte, trägt also zum Fehlermass in Gl. (8.3) mit dem quadrierten euklidschen Abstand zur Projektion bei. Mit diesem Fehlermass wird die Registrierung von geradlinigen korrespondierenden Segmenten in den Tiefenbildern bevorzugt.

Sei $\mathcal{C} := \{q_c \in \mathcal{Q}_t\}_{c=1}^C$ die Menge der C Punkte $q_c \in \mathcal{Q}_t$, für die die Projektion $\pi_c := \Pi(q_c, \mathcal{Q}_{t-1})$ existiert. Die Menge der Projektionen wird mit $\mathcal{P} := \{\pi_c\}_{c=1}^C$ bezeichnet. Um Rotation und Translation zwischen den Punktmengen $\mathcal{C}$ und $\mathcal{P}$ zu bestimmen, werden sie zunächst mittelwertbereinigt:

$$\overline{q}_c := q_c - \underbrace{\frac{1}{C}\sum_{c=1}^{C} q_c}_{=:\mu_q}$$

$$\overline{\pi}_c := \pi_c - \underbrace{\frac{1}{C}\sum_{c=1}^{C} \pi_c}_{=:\mu_\pi}.$$

Rotation R und Translation Δp ergeben sich durch Singulärwertzerlegung von $W = \sum_{c=1}^{C} \overline{q}_c^T \overline{\pi}_c = USV^T$:

$$R = UV^T$$
$$\Delta p = \mu_\pi - R\mu_q$$

Das Verfahren wird iteriert, bis ermittelte Rotation und Translation konvergiert sind oder eine maximale Anzahl an Iterationen erreicht ist. Vor einer Iteration werden die Punkte in $\mathcal{Q}_t$ mit der zuletzt ermittelten Rotation und Translation transformiert. Liegt zum aktuellen Zeitpunkt eine Geschwindigkeitsschätzung $v = (v_x, v_y, \omega)^T$ vor, wird die erste Iteration mit $R = R(\Delta t\omega)$ und $\Delta p = \Delta t(v_x, v_y)^T$ initialisert.

Neben Rotation und Translation zwischen den betrachteten Punktmengen, ist es ebenfalls notwendig eine sinnvolle Schätzung der Unsicherheit in diesen Größen zu erhalten, damit die Bewegungsinformation im SLAM-Verfahren verwendet und mit Schätzungen anderer Sensoren zu einer guten Approximation der Bewegung und ihrer Unsicherheit fusioniert werden kann. Die Unsicherheit soll neben der Unsicherheit in den Tiefenobservationen auch die Unsicherheit in nicht observierbaren Dimensionen erfassen. Zur Bestimmung der Kovarianz für die Orientierungsänderung $\Delta\theta$ und die Translation Δp wird die in [49] vorgeschlagene Methode verwendet, da sie effizient berechnet werden kann und belegt wurde, dass sie die Unsicherheit in nicht observierbaren Dimensionen ausreichend gut erfasst.

Sei $x := (\Delta p_x, \Delta p_y, \Delta\theta)^T$ und sei $z := (q_{t-1,1}, \ldots, q_{t-1,K}, q_{t,1}, \ldots, q_{t,K})^T$. Das Fehlermass in Abhängigkeit von x sei $E(x) := E(R(\Delta\theta), \Delta p)$. Die Kovarianz $Q_{Scanmatch}$ wird durch folgende Approximation bestimmt:

$$Q_{Scanmatch} \approx \left(\frac{\partial^2 E}{\partial x^2}\right)^{-1} \frac{\partial^2 E}{\partial z \partial x} \Sigma_z \frac{\partial^2 E}{\partial z \partial x}^T \left(\frac{\partial^2 E}{\partial x^2}\right)^{-1}$$

Die benötigten zweiten Ableitungen können in geschlossener Form berechnet werden. Wird stochastische Unabhängigkeit zwischen den Punktobservationen angenommen, ist Σ_z diagonal, und die Berechnung wird erheblich vereinfacht.

Die Ausgabe des Verfahrens ist eine normalverteilte Schätzung $((\Delta p_x, \Delta p_y, \Delta\theta)^T, Q_{Scanmatch})$ der Bewegung des Roboters, die die Pose s_{t-1} in die Pose s_t überführt. Abb. 8.8 zeigt Beispiele für das Verfahren.

8.6.3 Fusion der Bewegungsinformationen

Mit den zur Verfügung stehenden Bewegungsinformationen aus Inertialsensor und Scanmatching kann eine normalverteilte, partikelunabhängige Geschwindigkeitsschätzung $(\mu_{v,t}, \Sigma_{v,t})$ unterhalten werden. Die Messungen des Inertialsensors werden in der Beschleunigung $a_t := (a_{t,x}, a_{t,y}, a_{t,\omega})^T$ zusammengefasst. Die Beschleunigungskomponente $a_{t,\omega} = \frac{(\omega_t - \omega_{t-1})}{\Delta t}$ wird durch Differenzierung aus den vertikalen Drehraten des aktuellen und des letzten Zeitschritts angenähert.

Das approximative lineare Zustandsübergangsmodell

$$v_t = v_{t-1} + \Delta t \; a_t + \epsilon_t, \epsilon_t \sim \mathcal{N}(0, R_t^v)$$

modelliert die Änderung der Geschwindigkeit v_{t-1} durch die Beschleunigung a_t in diskreten Zeitschritten. Der Zustandsübergang unterliegt dabei normalverteiltem Rauschen.

Das Scanmatching liefert Translation Δp, Orientierungsänderung $\Delta\theta$ und die zugehörige Kovarianz $Q_{scanmatch}$ zwischen dem letzten und aktuellen Tiefenbild. Der Versatz wird als Observation $z_t^v = \frac{1}{\Delta t}(\Delta p_x, \Delta p_y, \Delta\theta)^T$ der Geschwindigkeit aufgefasst. Die Kovarianz $Q_t^v = (\frac{1}{\Delta t}\ I)Q_{scanmatch}(\frac{1}{\Delta t}\ I)^T = \frac{1}{\Delta t^2}Q_{scanmatch}$ der Observation ergibt sich durch Fehlerpropagation erster Ordnung.

Das lineare Observationsmodell

$$z_t^v = v_t + \delta_t, \delta_t \sim \mathcal{N}(0, Q_t^v)$$

erklärt z_t^v als Observation der aktuellen Geschwindigkeit, die mit normalverteiltem Rauschen behaftet ist.

Ein lineares Kalmanfilter wird zur Bestimmung der Vorhersage $(\overline{\mu}_{v,t}, \overline{\Sigma}_{v,t})$ aus der Geschwindigkeitsschätzung $(\mu_{v,t-1}, \Sigma_{v,t-1})$ des letzten Zeitschritts verwendet:

$$\begin{aligned}\overline{\mu}_{v,t} &= \mu_{v,t-1} + a_t \\ \overline{\Sigma}_{v,t} &= \Sigma_{v,t-1} + R_t^v\end{aligned}$$

Die Vorhersage wird mit der aktuellen Observation z_t^v zur Geschwindigkeitsschätzung $(\mu_{v,t}, \Sigma_{v,t})$ korrigiert:

$$\begin{aligned}K &= \overline{\Sigma}_{v,t}(\overline{\Sigma}_{v,t} + Q_t^v)^{-1} \\ \mu_{v,t} &= \mu_{v,t-1} + K(z_t^v - \mu_{v,t-1}) \\ \Sigma_{v,t} &= (I - K)\Sigma_{v,t-1}\end{aligned}$$

Die aktuelle Geschwindigkeitsschätzung wird als Kontrolleingabe $u_t = \mu_{v,t}$ mit Kovarianz $V_t = \Sigma_{v,t}$ für die initiale Posenschätzung in Abschnitt 6.4 verwendet.

8.6.4 Posenkorrektur durch Tiefenbildregistrierung

Das Wandmodell besitzt einen weiteren Nutzen für die Korrektur der Posenschätzung durch das Tiefenbild. Die Idee besteht darin, die Orientierungen von Wänden im Tiefenbild mit der Hauptorientierung in der Karte zu registrieren, indem die Orientierung der Posenschätzung entsprechend korrigiert wird. Damit wird die Unsicherheit in der Orientierung stark reduziert, sodass sich die Unsicherheit in der Trajektorie im wesentlichen auf die kartesischen Posenkoordinaten beschränkt.

Im Tiefenbild wird die Hauptorientierung der Wandsegmente auf folgende Weise geschätzt: In diskreten Abtastpunkten wird innerhalb eines Fensters nach Gl. (B.1) eine Gerade durch die kartesischen Punkte approximiert. Die Orientierung einer approximierten Gerade wird mit einer festen Varianz in ein Orientierungshistogramm integriert (s. Abschnitt 7.5.1), falls folgende Bedingungen erfüllt sind:

- Die Tiefenmessungen im Fenster besitzen eine hohe durchschnittliche Detektionssicherheit.
- Aufeinanderfolgende Punkte im Tiefenbild besitzen einen geringen kartesischen Abstand.
- Das Verhältnis zwischen mittlerer quadratischen Abweichung und geschätzter Linienlänge ist kleiner als ein Schwellwert.
- Die geschätzte Linienlänge ist ausreichend gross für eine zuverlässige Orientierungsschätzung.

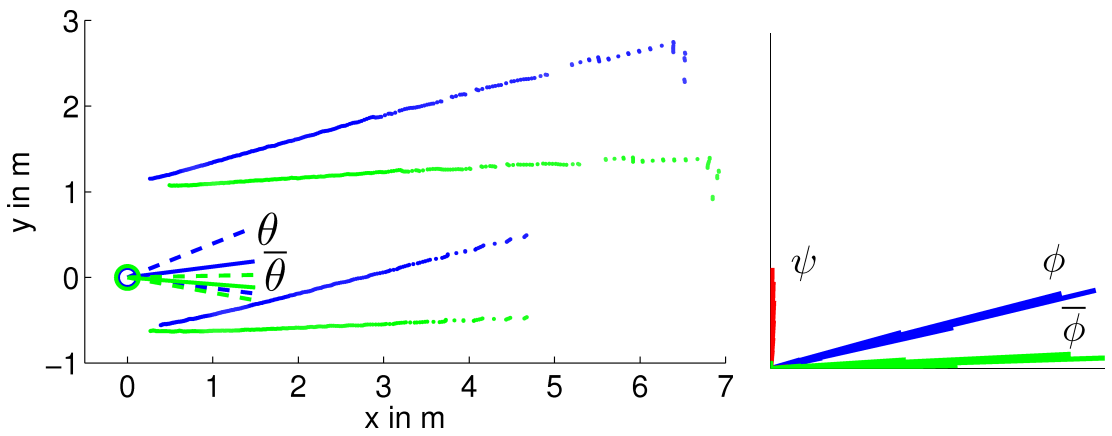

Abbildung 8.9: Beispiel für die Posenkorrektur durch Registrierung des Tiefenbilds mit der Hauptorientierung ψ. In der ursprünglichen Pose (blau) mit Orientierung θ besitzt das Tiefenbild (blau) die globale Orientierung ϕ. Nach der Korrektur der Pose in die neue Orientierung $\overline{\theta}$ (grün) entspricht die globale Orientierung $\overline{\phi}$ des Tiefenbilds (grün) der Hauptorientierung besser. Die 2σ-Umgebungen der Orientierungsschätzungen sind jeweils durch gestrichelte Linien angegeben.

Aus dem Orientierungshistogramm erhält man die Schätzung (ϕ, σ_ϕ^2) für die Hauptorientierung im Tiefenbild durch Meanshift analog zu Abschnitt 7.5.1.

Für jedes Partikel wird die initiale Posenschätzung $\left(\hat{s}_t^{[i]}, R_t^{[i]}\right)$ korrigiert, indem die Hauptorientierung im Tiefenbild als Observation der Hauptorientierung $(\psi^{[i]}, \sigma_{\psi^{[i]}}^2)$ in der Karte des Partikels aufgefasst wird:

$$z_t^\psi = h(s_t, \psi) + \delta_t = \psi - \theta_t + \delta_t, \delta_t \sim \mathcal{N}(0, Q_t^\psi)$$

Mit der Innovation $\Delta\phi := cyc(\phi - h(\hat{s}_t^{[i]}, \psi^{[i]}), -\frac{\pi}{2}, \frac{\pi}{2})$ und der Unsicherheit $Q_t^\psi := \sigma_\phi^2 + \sigma_{\psi^{[i]}}^2$ in der Observation, die die Unsicherheit in der Schätzung der Kartenhauptorientierung berücksichtigt, wird die Posenschätzung in einem EKF-Korrekturschritt aktualisiert:

$$\begin{aligned}
H_{s_t} &:= \nabla_{s_t} h(s_t, \psi)|_{\hat{s}_t^{[i]}, \psi^{[i]}} \\
K &= R_t^{[i]} H_{s_t}^T \left(H_{s_t} R_t^{[i]} H_{s_t}^T + Q_t^\psi\right)^{-1} \\
\hat{s}_t^{[i]} &\leftarrow \hat{s}_t^{[i]} + K\Delta\phi \\
R_t^{[i]} &\leftarrow (I - KH_{s_t}) R_t^{[i]}
\end{aligned}$$

Die Korrektur wird nur dann vorgenommen, falls die Hauptorientierung der Wandsegmente in der Karte bereits ausreichend sicher geschätzt ist. Abb. 8.9 skizziert das Verfahren in einem Beispiel.

9 Experimentelle Ergebnisse

In diesem Kapitel wird das vorgestellte Verfahren experimentell evaluiert. In der Simulationsumgebung werden Kartierungs- und SLAM-Verfahren ohne die Verwendung von Tiefeninformationen untersucht und die Vorteile des Wandmodells demonstriert. Anschliessend werden Experimente des erweiterten Verfahrens im realen Szenario präsentiert und Grenzen des Ansatzes aufgezeigt.

9.1 Experimente in der Simulationsumgebung

In der Simulation ist die tatsächliche Pose und eine exakte Karte der Umgebung für eine quantitative Auswertung des Verfahrens verfügbar. Der Sichtbereich des Roboters wird in den Experimenten zu $\alpha_{FOV} = 120°$ gewählt. Während sich der Roboter durch die Umgebung bewegt, werden mit einer Frequenz von $f_{Bildaufnahme} = 5\text{Hz}$ eindimensionale Bildmessungen generiert. Rotations- und Translationsgeschwindigkeit sind im Betrag durch $0.2\frac{rad}{s}$ bzw. $0.2\frac{m}{s}$ beschränkt. Das Bewegungsrauschen in der Simulation wird analog zu Abschnitt 6.1 in Abhängigkeit der einzelnen Zielgeschwindigkeitskomponenten modelliert. Die Parameter des Modells sind in Tabelle 9.1 aufgeführt.

9.1.1 Kartieren bei bekannter Pose

Kartieren einer Beispielumgebung mit Schleifen und konvexen Ecken

Das folgende Experiment soll die Fähigkeit des Verfahrens demonstrieren, eine Beispielumgebung mit Schleifen und konvexen Ecken zu kartieren. Die Umgebung wird in späteren Experimenten dazu dienen, das SLAM-Verfahren zu evaluieren.

Die Zieltrajektorie des Roboters ist durch eine Abfolge von Zielposen definiert, die in Abb. 9.1 angegeben ist. Der Roboter bewegt sich zuerst in einer Schleife durch den rechteckigen Raum zurück zur Startposition. Der Raum wird verlassen und die grosse Schleife nach rechts begonnen. In den Ecken dreht der Roboter jeweils zurück, um die konvexen Ecken der Innenwände erfassen zu können. Nach einem vollständigen Rundgang durch die grosse Schleife wird der rechteckige Raum wieder betreten. Die letzte Zielpose befindet sich inmitten des Raums, wobei der Roboter der rechten Wand zugewandt ist.

In Abb. 9.2 ist das Ergebnis des Kartierungsverfahrens dargestellt. Die Positionen der Kantenlandmarken stimmen bis auf wenige Millimeter mit den tatsächlichen Positionen

	$\alpha_{\cdot,1}$	$\alpha_{\cdot,2}$	$\alpha_{\cdot,3}$
x	0.25	0.05	$0.015/\pi$
y	0.05	0.25	$0.015/\pi$
w	0.025π	0.025π	0.25

Tabelle 9.1: Parameter des Rauschens im simulierten Bewegungsmodell.

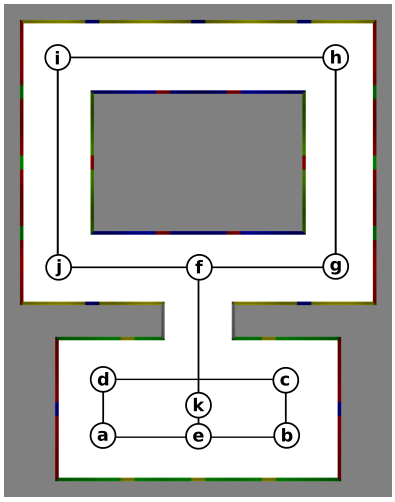

t	p	θ	t	p	θ
1	a	$\rightarrow$	814	f	$\rightarrow$
135	b	$\uparrow$	931	g	$\uparrow$
190	c	$\leftarrow$	969	g	$\leftarrow$
230	c	$\downarrow$	1137	h	$\leftarrow$
265	c	$\leftarrow$	1177	h	$\downarrow$
402	d	$\downarrow$	1391	i	$\downarrow$
455	a	$\rightarrow$	1430	i	$\rightarrow$
493	a	$\uparrow$	1598	j	$\rightarrow$
529	a	$\rightarrow$	1636	j	$\uparrow$
605	e	$\uparrow$	1755	f	$\downarrow$
741	f	$\rightarrow$	1866	k	$\rightarrow$
778	f	$\downarrow$			

Abbildung 9.1: Abfolge von Zielposen im Schleifenexperiment.

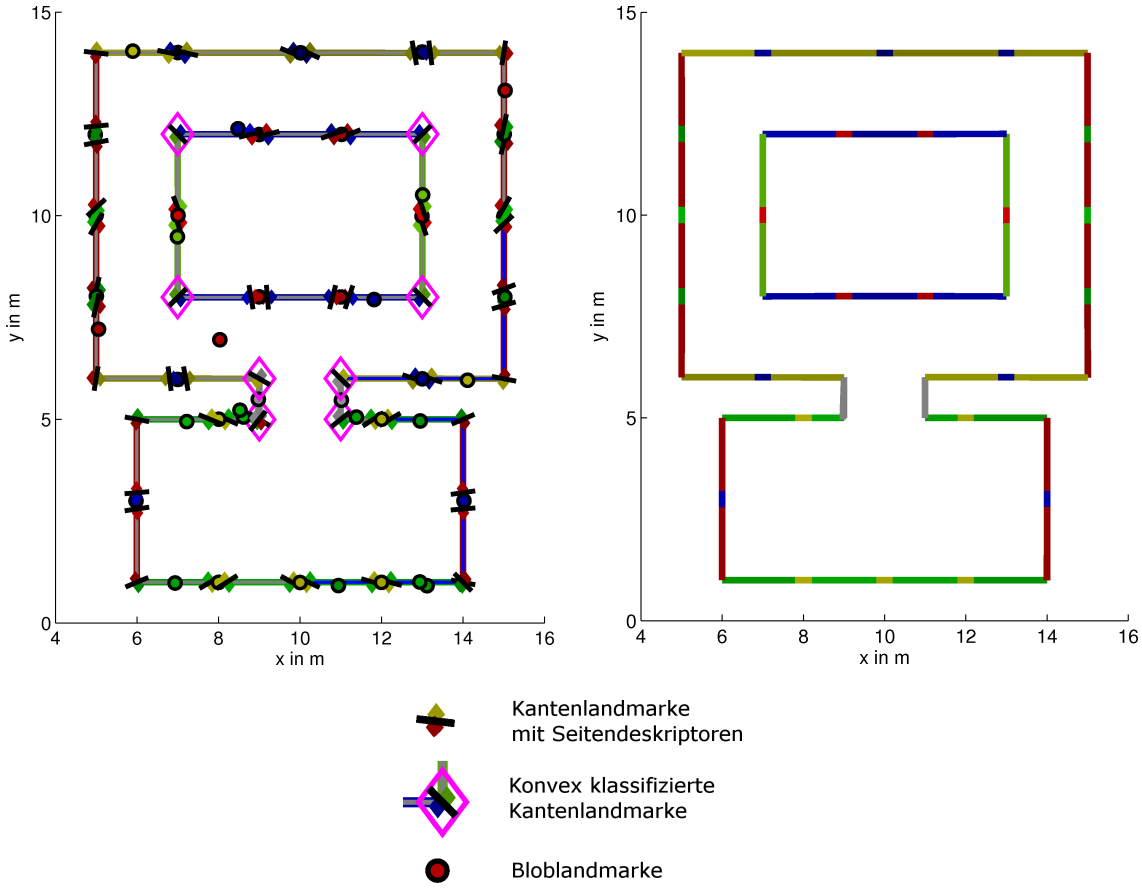

Abbildung 9.2: Ergebnisse des Kartierungsverfahrens. Links: Karte mit Landmarken und Wänden. Rechts: Karte der Wandsegmente. Die Positionen der Kantenlandmarken stimmen bis auf wenige Millimeter mit den tatsächlichen Positionen der Wandsegmentübergänge überein.

der Wandsegmentübergänge überein. Auch das Wandmodell bildet die Simulationsumgebung akkurat ab. Aufgrund der geschickten Wahl der Trajektorie konnten alle konvexen Ecken in der Umgebung korrekt kartiert werden.

Aus Abb. 9.3 ist ersichtlich, dass nach dem Schliessen der grossen Schleife im Zeitschritt $t = 1598$ die Anzahl an Landmarken in der Karte nahezu konstant bleibt. Die zu Beginn eingefügten Landmarken können also reassoziiert werden. In der Landmarkenzahl sind kurzzeitige Abstiege zu erkennen, die hohen Anstiegen folgen. Zu diesen Zeitpunken, beispielsweise $t = 190$, ändert der Roboter seine Orientierung stark, sodass kürzlich initialisierte Landmarken aus dem Sichtbereich verschwinden und aufgrund der Kriterien in Abschnitt 6.8.6 aus der Karte entfernt werden.

In jedem Zeitschritt wird der größte Anteil der observierten Merkmale mit Landmarken assoziiert. Für Blobmerkmale ist eine deutlich höhere Initialisierungsrate als für Kantenmerkmale zu erkennen. Das liegt im wesentlichen an der geringeren Detektionsstabilität der Blobmerkmale. Die höhere Auslassungsrate liegt darin begründet, dass Blobmerkmale an ähnlichen Orten im Bild in multiplen Skalen detektiert werden können, sodass Merkmale nicht mehr eindeutig mit Landmarken assoziiert werden können. In der unteren Reihe der Abbildungen ist zu sehen, dass insbesondere für Kantenlandmarken ein grosser Anteil der Datenassoziationen durch die effizientere Variante der Merkmalsverfolgung hergestellt wird.

An Tiefendiskontinuitäten treten Kantenmerkmale auf, die keiner Grenze zwischen Wandsegmenten in der Umgebungsstruktur entsprechen. Ausserdem ist es möglich, dass durch virtuelle Wandsegmente eigentlich bereits kartierte Bereiche kurzzeitig verdeckt sind. Aus diesen Gründen können Landmarken mehrfach in die Karte eingefügt werden. Die Überprüfung der Detektionsrate sorgt jedoch dafür, dass die mehrfach eingefügten Landmarken nach einer gewissen Anzahl an Fehldetektionen aus der Karte entfernt werden.

Standpunktumkehr und Wandmodell

Das folgende Experiment soll die Nützlichkeit des Wandmodells für die Einschränkung der möglichen Sichtbarkeit von Landmarken und damit für die Vermeidung von Datenassoziationsfehlern belegen. Die Versuchsanordnung mit der Abfolge an Zielposen ist in Abb. 9.4 gegeben. Die Umgebung besteht aus zwei Räumen, die durch ein schmales Wandsegment mit einem Durchgang getrennt sind. Zu beiden Seiten des Durchgangs befindet sich auf den Wänden eine Dekoration in Form einer farbigen Unterbrechung, die auf beiden Wandseiten symmetrisch ist. Der Roboter bewegt sich im Experiment vom linken in den rechten Raum und wieder zurück zur Ausgangsposition.

In Abb. 9.5 sind Kartierungsergebnisse des Verfahrens ohne (rechte Spalte) und mit (linke Spalte) Modellierung von Wänden in ausgewählten Zeitpunkten $t \in \{120, 304, 604\}$ dargestellt. Die Kantenlandmarken innerhalb der vertikalen Wände werden auf ihren Seiten komplementär beschrieben. Gegenüberliegende symmetrische Landmarken sind jedoch aufgrund des modellierten Rauschens im Observationsmodell in ihrem Ort im Bild nicht eindeutig unterscheidbar, falls der Abstand des Roboters zu den Landmarken ausreichend gross ist. Die vertikalen Wandsegmente werden von einer Betrachtungsseite kartiert. Werden die Wandsegmente von der gegenüberliegenden Seite betrachtet, kann die Verwechslung der Kantenlandmarken nur dann ausgeschlossen werden, falls das mögliche Sichtbarkeitswinkelintervall im Standpunkt der Landmarke den Sichtwinkel zur Pose des Roboters ausschliesst. Zum Zeitpunkt $t = 120$ sind für beide Verfahren die Kantenland-

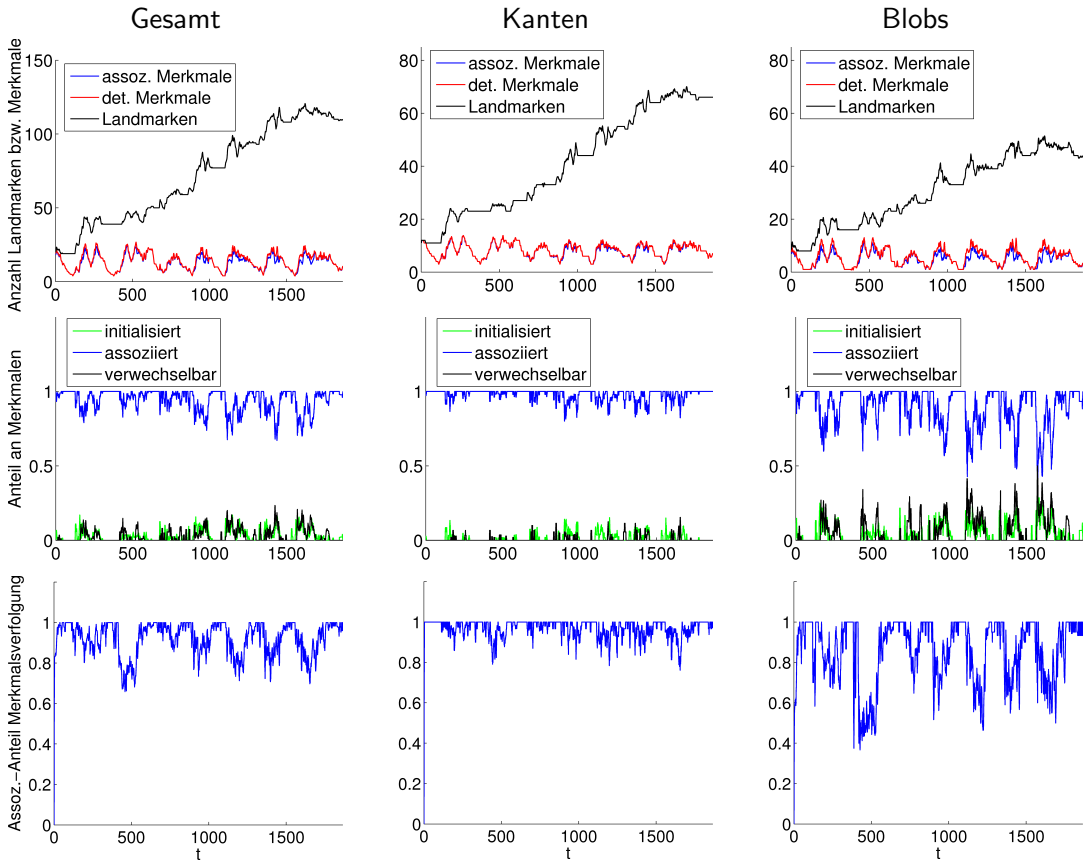

Abbildung 9.3: Merkmale, Landmarken und Datenassoziationen im Kartierungsexperiment. Obere Reihe: Anzahl an Landmarken (schwarz), detektierte Merkmale (rot) und assoziierte Merkmale (blau) je Zeitschritt. Mittlere Reihe: Anteil der assoziierten Merkmale (blau), der Merkmale, die zu Landmarkeninitialisierungen führen, (grün) und der verwechselbaren, unberücksichtigten Merkmale (schwarz) an der Gesamtzahl Merkmale. Untere Reihe: Anteil der Landmarkenassoziationen durch Merkmalsverfolgung an der Gesamtzahl Landmarkenassoziationen. In den Spalten jeweils für beide Landmarken-/Merkmalstypen (links), Kantenlandmarken/-merkmale (mitte) und Bloblandmarken/-merkmale (rechts).

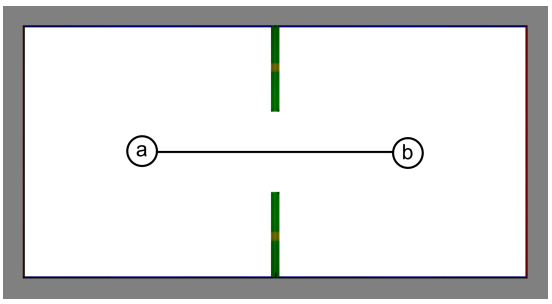

t	p	θ
1	a	$\rightarrow$
304	b	$\leftarrow$
604	a	$\rightarrow$

Abbildung 9.4: Abfolge von Zielposen im Standpunktumkehrexperiment.

marken der vertikalen Wände korrekt kartiert. Bei umgekehrtem Standpunkt des Roboters auf die vertikale Wand in $t = 304$ werden die zuvor kartierten Kantenlandmarken im Verfahren ohne Wandmodellierung fälschlicherweise reassoziiert. Im Gegensatz dazu ist die Assoziation mit den Kantenlandmarken mit Wandmodellierung nicht möglich, da die möglichen Sichtwinkel durch das Wandmodell eingeschränkt sind. Die falsche Datenassoziation führt zu einem erheblichen Kartierungsfehler, was in der SLAM-Anwendung zur Divergenz des Verfahrens führen kann.

Verdeckungen durch Wandsegmente

Mit der Versuchsanordnung in Abb. 9.6 soll gezeigt werden, wie das Sichtbarkeitskonzept der Verdeckung durch Wandsegmente die Datenassoziation verbessert. Die Umgebung besteht aus zwei Räumen, die durch einen Flur verbunden sind. Die linken Wände der beiden Räume sind identisch texturiert und enthalten in ihrer Mitte einen Übergang von einem grünen zu einem gelben Wandsegment, der als Kante beobachtet wird. Der Roboter kartiert zunächst den linken Raum in einer Schleife und begibt sich anschliessend über den Flur in den rechten Raum. Dort schwenkt er in der Mitte des Raums zur linken Wand, sodass beide Wandmitten in ähnlichem Winkel im Bild erscheinen.

Abb. 9.7 enthält Kartierungsergebnisse des Verfahrens mit und ohne Wandmodellierung. Zum Zeitpunkt $t = 538$ konnten beide Verfahren den linken Raum korrekt kartieren. Ohne Kenntnis der Tiefe ist es im Zeitschritt $t = 1131$ für das Kartierungsverfahren ohne Wandmodellierung nicht möglich, die Farbübergänge auf der jeweils linken Wand in den beiden Räumen zu unterscheiden, sodass eine falsche Datenassoziation auftritt. Bewegt sich der Roboter mit Parallaxe zu dieser Kantenlandmarke weiter, wird die Position der Landmarke verfälscht. Im vorliegenden Beispiel beträgt die Abweichung von der tatsächlichen Position nach 45 Zeitschritten bzw. 9 sec ca. 18.8 cm.

Mit Modellierung von Wänden wird im Zeitschritt $t = 1131$ die Kantenlandmarke im linken Raum durch die rechte Wand des linken Raums verdeckt. Anstelle einer falschen Assoziation wird für das beobachtete Merkmal eine Kantenlandmarke initialisiert, deren Tiefe im Mittelwert auf die Tiefe zur Wand gesetzt wird.

9.1.2 Simultanes Lokalisieren und Kartieren

Im folgenden Abschnitt wird das SLAM-Verfahren anhand von Winkelobservationen evaluiert. Es wird ausserdem die Korrektur von Wandsegmenten auf die Hauptorientierung zur Laufzeit untersucht. Die Standardabweichung des zusätzlich modellierten

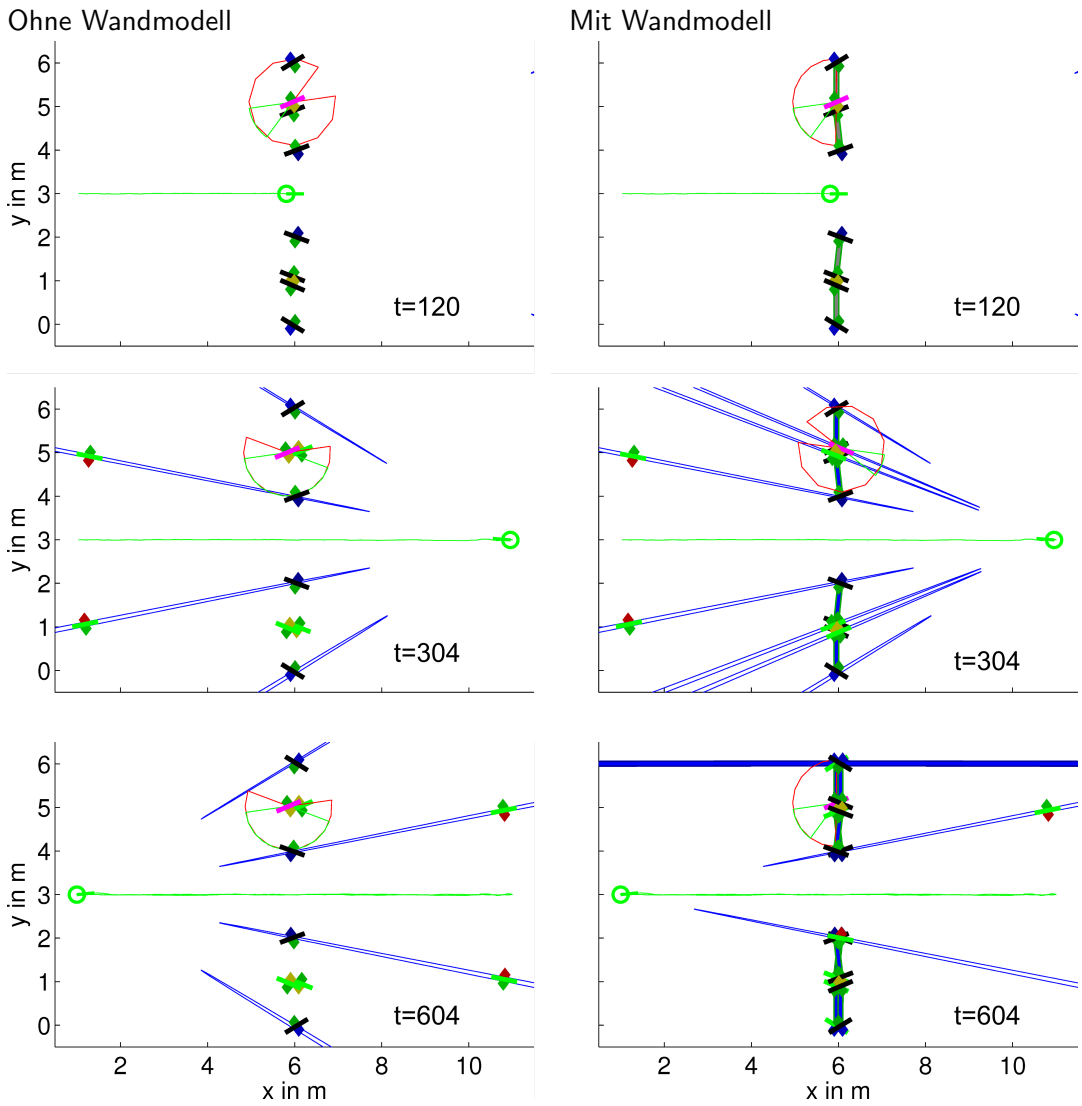

Abbildung 9.5: Links: Kartierungsergebnis im Standpunktumkehrexperiment ohne Wandmodellierung in ausgewählten Zeitpunkten. Rechts: Kartierungsergebnis im Standpunktumkehrexperiment mit Wandmodellierung zu den gleichen Zeitpunkten. Das Wandmodell schränkt das mögliche Sichtbarkeitswinkelintervall von Landmarken ein, sodass falsche Assoziationen verhindert werden können. Für die magenta markierten Kantenlandmarken werden detektiertes (grün) und mögliches (rot) Sichtbarkeitswinkelintervall im Standpunkt der Landmarke durch Kreisauschnitte visualisiert. Im aktuellen Zeitschritt assoziierte Landmarken sind grün markiert. Die Unsicherheit in der Landmarkenpositionsschätzung wird durch ihre σ-Umgebung (blau) dargestellt. Auf die Darstellung von Bloblandmarken wurde aus Gründen der Übersichtlichkeit verzichtet.

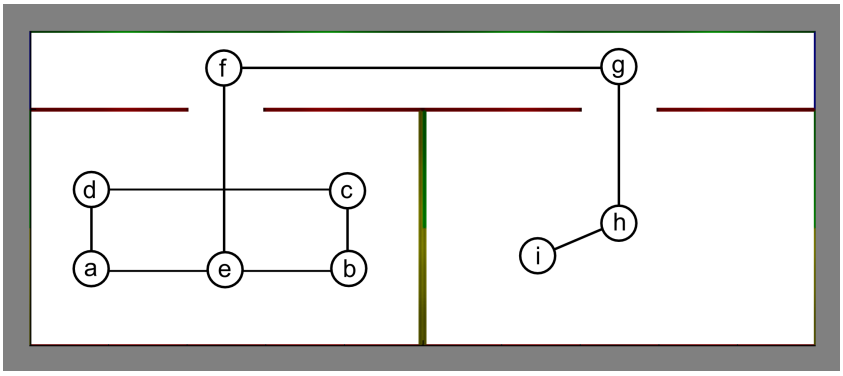

t	p	θ
1	a	$\rightarrow$
164	b	$\uparrow$
223	c	$\leftarrow$
387	d	$\downarrow$
449	a	$\rightarrow$
538	e	$\uparrow$
682	f	$\rightarrow$
949	g	$\downarrow$
1086	h	$\leftarrow$
1131	i	$\leftarrow$

Abbildung 9.6: Abfolge von Zielposen im Verdeckungsexperiment.

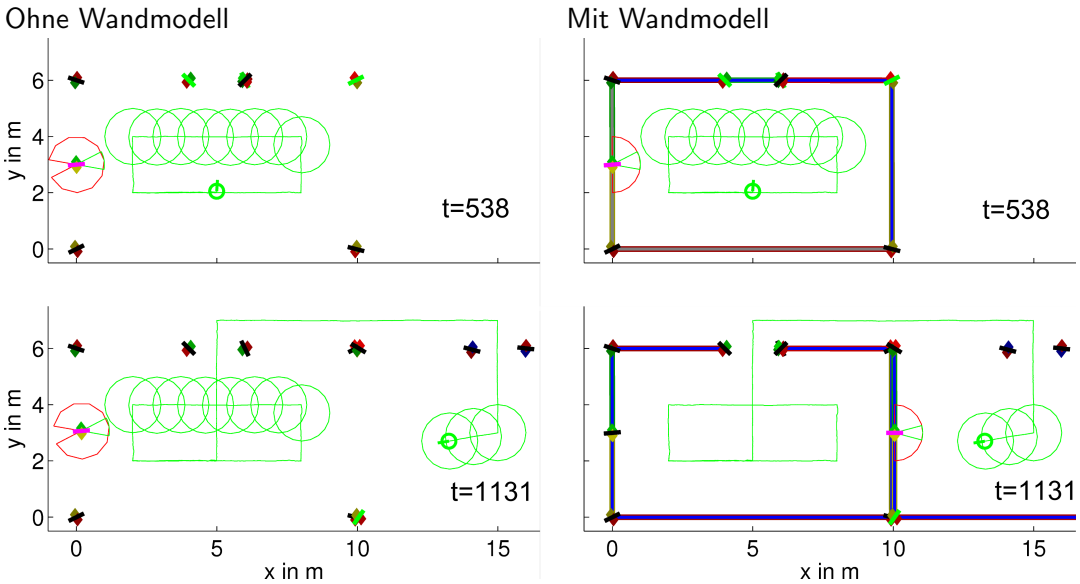

Abbildung 9.7: Links: Kartierungsergebnis im Verdeckungsexperiment ohne Wandmodellierung in ausgewählten Zeitpunkten. Rechts: Kartierungsergebnis im Verdeckungsexperiment mit Wandmodellierung zu den gleichen Zeitpunkten. Verdeckungen durch das Wandmodell verhindern falsche Datenassoziationen. Für die magenta markierten Kantenlandmarken werden detektiertes (grün) und mögliches (rot) Sichtbarkeitswinkelintervall im Standpunkt der Landmarke durch Kreisauschnitte visualisiert. Die Umgebungen der detektierten Sichtbarkeitsorte der markierten Landmarke sind als grüne Kreise dargestellt. Im aktuellen Zeitschritt assoziierte Landmarken sind grün markiert. Auf die Darstellung von Bloblandmarken wurde aus Gründen der Übersichtlichkeit verzichtet.

Orientierungsfehlers im Bewegungsmodell wird in den folgenden Experimenten durch $\alpha_{\gamma,1} = 0.075\pi$, $\alpha_{\gamma,2} = 0.075\pi$ und $\alpha_{\gamma,3} = 0.75$ parametrisiert.

Evaluation des Standardverfahrens

Die Schleifenumgebung aus Abschnitt 9.1.1 wird verwendet, um das SLAM-Verfahren zu evaluieren. Zunächst wird es an einer exemplarischen Episode analysiert, für die in Abb. 9.8 die Schätzung von Trajektorie und Karte des Partikels mit höchstem Gewicht in ausgewählten Zeitpunkten illustriert ist. In Abb. 9.8.a) befindet sich der Roboter kurz vor dem Schliessen der kleinen Schleife im unteren Raum. Abb. 9.8.b) zeigt die Schätzung von Trajektorie und Karte nach dem Schleifenschluss. Die Schätzung in Abb. 9.8.c) besteht kurz vor dem Schliessen der grossen Schleife, die in Abb. 9.8.d) geschlossen ist.

Die mittlere geschätzte Trajektorie aus den Bewegungsinformationen in Abb. 9.9.b) weicht trotz der geringen Bewegungsgeschwindigkeit vor allem in der Orientierung stark von der tatsächlichen Trajektorie des Roboters ab. Das SLAM-Verfahren ist in der Lage, den Verlauf der tatsächlichen Trajektorie in einer guten Näherung zu schätzen. Die Karte des besten Partikels in Abb. 9.9.a) ist bis auf wenige Fehlkartierungen und kleine Abweichungen in den Landmarkenpositionen dem Kartierungsergebnis qualitativ sehr ähnlich. Kartierungsfehler treten auf, wenn über längere Zeiträume nur wenige Merkmale observiert werden, oder Merkmale an Verdeckungen extrahiert werden, die nicht der Umgebungsstruktur entsprechen.

Abb. 9.9.c) zeigt die Unsicherheit in der Posenschätzung je Zeitschritt. Bei der Exploration neuer Kartenbereiche ist sie hoch, während sie gering ist, wenn der Roboter bereits kartierte Bereiche beobachtet. Die Trajektorienentropie in Abb. 9.9.d) besitzt bis zum Zeitpunkt $t = 200$ einen hohen Anstieg. Anschliessend schwenkt der Roboter in seiner Orientierung, sodass ein Teil der zuvor kartierten Umgebung in den Blickwinkelbereich gerät. Die Trajektorienentropie sinkt geringfügig, steigt aber wieder bis zum Zeitschritt $t = 455$ an, da der Roboter die gegenüberliegende, bislang unkartierte Seite des unteren Raums exploriert. Nach dem Schluss der kleinen Schleife in Zeitschritt $t = 455$ sinkt die Unsicherheit stark. Innerhalb der grossen Schleife orientiert sich der Roboter in den Ecken zurück, um die konvexen Ecken kartieren zu können. Dabei geraten bereits explorierte Bereiche in das Sichtfeld zurück, sodass die Trajektorienunsicherheit in der grossen Schleife zwar insgesamt steigt, aber jeweils zu den Zeitpunkten $t \in \{931, 1137, 1391, 1598\}$ sinkt. Dass während der Erkundung der unbekannten Kartenbereiche dennoch hohe Unsicherheit in der Posenschätzung besteht, ist in den hohen Werten der Posenentropie zu erkennen. Nach dem Schluss der grossen Schleife im Zeitschritt $t = 1636$ sinken Posen- und Trajektorienentropie stark. Aus Abb. 9.9.e) ist ersichtlich, dass in den 1866 Iterationen des Partikelfilterverfahrens nur in 118 Zeitschritten eine Erneuerung der Partikelmenge durchgeführt wurde.

Posen- und Trajektorienentropie werden bestimmt, indem die Posenschätzung der Partikelmenge zum Zeitpunkt t normalverteilt mit $(\mu_{s_t}, \Sigma_{s_t})$ approximiert wird. Die Posenentropie ergibt sich näherungsweise als

$$H(p(s_t|u_{1:t}, z_{1:t})) \approx H\left(\mathcal{N}(\mu_{s_t}, \Sigma_{s_t})\right) = \log\left((2\pi e)^{\dim(s_t)/2} \left|\Sigma_{s_t}\right|\right). \tag{9.1}$$

Die Trajektorienentropie wird auf folgende Weise approximiert [50, 51]:

$$H(p(s_{1:t}|u_{1:t}, z_{1:t})) \approx \frac{1}{t} \sum_{t'=1}^{t} H(p(s_{t'}|u_{1:t'}, z_{1:t'})) \tag{9.2}$$

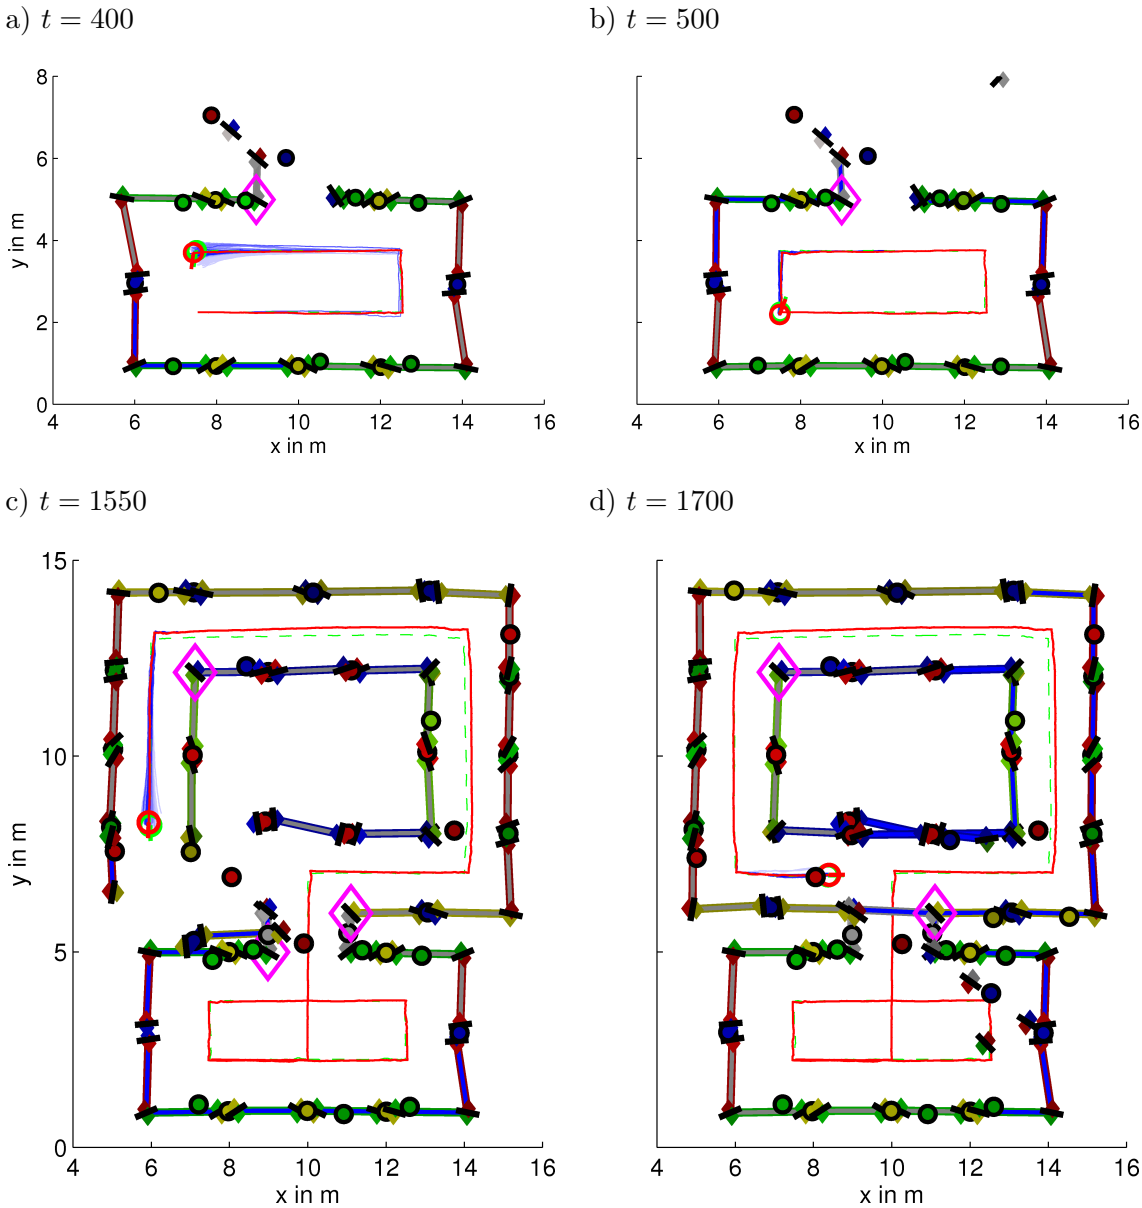

Abbildung 9.8: Illustration eines SLAM-Experiments in der simulierten Schleifenumgebung mit 200 Partikeln in ausgewählten Zeitpunkten. Es werden Karte und Trajektorie (rot) des Partikels mit aktuell höchstem Gewicht dargestellt. Die tatsächliche Trajektorie des Roboters ist grün gestrichelt visualisiert. Die Trajektorien der übrigen Partikel werden umso blauer dargestellt, je höher ihr Gewicht ist.

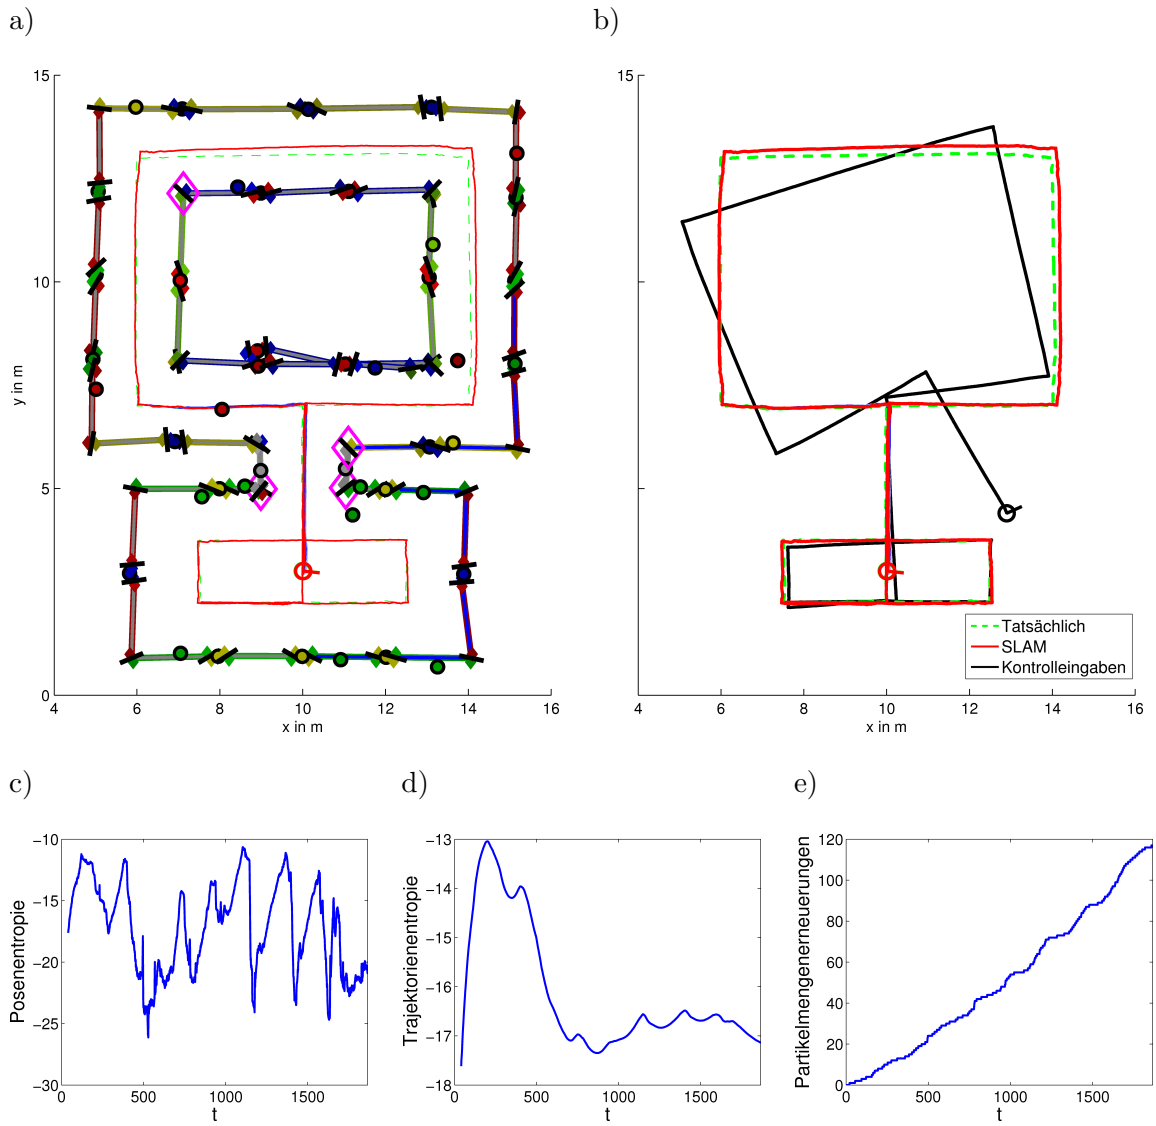

Abbildung 9.9: Ergebnisse eines SLAM-Experiments in der simulierten Schleifenumgebung mit 200 Partikeln. Die Karte des besten Partikels entspricht dem Kartierungsergebnis bis auf wenige Fehlkartierungen und geringe Abweichungen in den Landmarkenpositionen in guter Näherung. Bild a: Karte und Trajektorie (rot) des besten Partikels im letzten Zeitschritt. Die tatsächliche Trajektorie des Roboters ist grün gestrichelt dargestellt. Bild b: Vergleich zwischen Trajektorie des besten Partikels (rot), tatsächlicher Trajektorie (grün gestrichelt) und mittlerer Trajektorie aus den Bewegungsinformationen (schwarz). Bild c: Posenentropie der Partikelmenge. Bild d: Trajektorienentropie der Partikelmenge. Bild e: Anzahl an Erneuerungen der Partikelmenge seit Episodenbeginn.

# Partikel (M)	20	50	100	200
Kleine Schleife	7	9	10	10
Grosse Schleife	2	6	7	10

Tabelle 9.2: Anzahl Schleifenschlüsse in 10 Läufen für unterschiedliche Anzahlen an Partikeln im simulierten Schleifenexperiment.

Um die Zuverlässigkeit des Verfahrens und die benötigte Anzahl an Partikeln zu erfassen, wurden jeweils 10 Läufe für unterschiedliche Partikelzahlen durchgeführt. Tabelle 9.2 führt für die ausgewählten Partikelanzahlen $M \in \{20, 50, 100, 200\}$ die Anzahl Schleifenschlüsse für die kleine Schleife im unteren Raum und die grosse Schleife im rechteckigen Korridor auf. Die Ergebnisse weisen darauf hin, dass für eine hohe Zuverlässigkeit im Schliessen der grossen Schleife 200 Partikel ausreichend sind.

Korrektur der Wandsegmente auf die Hauptorientierung

Die heuristische Registrierung der Wandsegmentorientierungen auf die Hauptorientierung in der Karte wird im folgenden episodisch in der simulierten Schleifenumgebung untersucht. In Abb. 9.10 sind typische Ergebnisse des SLAM-Verfahrens mit Wandkorrektur auf die Hauptorientierung dargestellt.

Der mittlere Orientierungsfehler der Partikelmenge wird als gewichtetes Mittel aus den Orientierungsfehlern der einzelnen Partikel zur tatsächlichen Orientierung des Roboters approximiert, wobei die aktuellen Gewichte der Partikel verwendet werden. Die mittlere Hauptorientierung ergibt sich ebenfalls näherungsweise aus dem gewichteten Mittel der einzelnen Hauptorientierungen in den Partikelkarten.

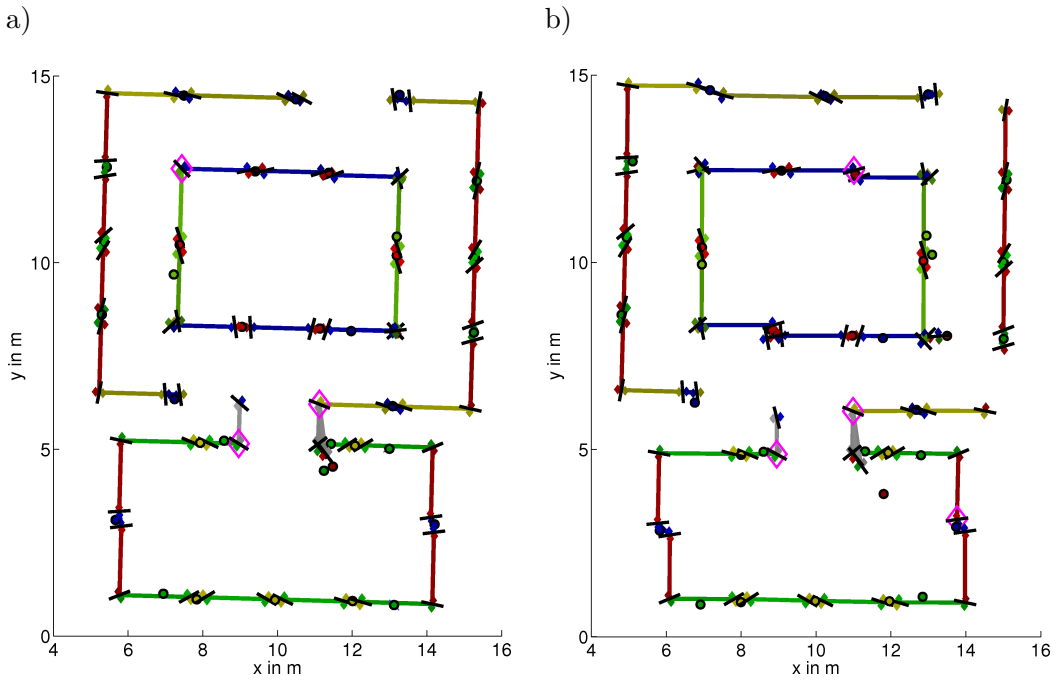

Abbildung 9.10: Typische Ergebniskarten des SLAM-Verfahrens mit Korrektur der Wandsegmente auf die Hauptorientierung der Karte im Schleifenexperiment.

In der linken Karte trat während des Laufs nur eine geringe Orientierungsdrift auf (s. Abb. 9.11), sodass bis auf wenige fehlende Wandsegmente ein qualitativ sehr gutes Ergebnis erzielt werden konnte. Das Fehlen von Wandsegmenten tritt auch im Standardverfahren auf. Geringe Orientierungsfehler in der grossen Schleife führen dazu, dass sich die Hauptorientierung durch die neu eingefügten Wände in der Schleife geringfügig ändert. Die Orientierungen der Wände im unteren Raum werden deshalb auf die sich ändernde Hauptorientierung angepasst. Das Verfahren besitzt die Eigenschaft, Orientierungsfehler von langen Wandsegmenten stärker auszugleichen als von kurzen, sodass ein Versatz in kürzeren Wandsegmenten auftritt.

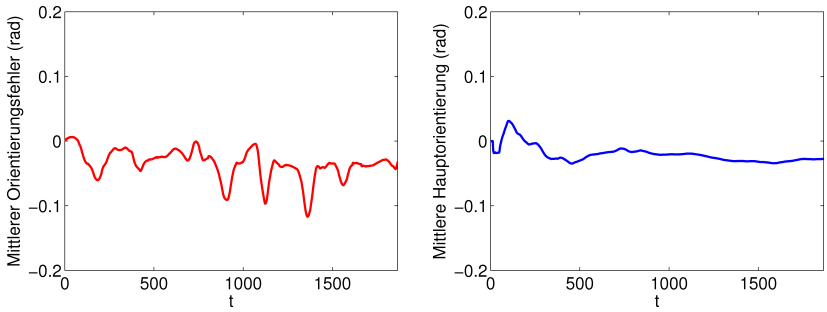

Abbildung 9.11: Mittlerer Orientierungsfehler (links) und mittlere Hauptorientierung (rechts) für das Experiment in Abb. 9.10.a).

In der rechten Karte tritt ab dem Zeitpunkt $t \approx 1100$ ein hoher Orientierungsfehler in der Posenschätzung innerhalb der grossen Schleife auf, wie in Abb. 9.12 ersichtlich ist. Die in der fälschlichen Orientierung kartierten Wandsegmente werden erst um den Zeitschritt $t \approx 1450$ für Hauptorientierungsschätzung und -korrektur berücksichtigt, nachdem sie ausreichend sicher geschätzt sind. Die Wandsegmente werden stark korrigiert und die Schätzung der Hauptorientierung ändert sich in erheblichem Maße zur Ausgangsorientierung der neuen Wandsegmente. Damit werden auch alte Kartenbereiche stark verfälscht. Die Drift in der Posenorientierung wird ab dem Zeitpunkt $t \approx 1598$ bei der Wiederkehr in bereits kartierte Bereiche behoben. Zu diesem Zeitpunkt ist die Hauptorientierung bereits irreversibel verfälscht.

Die durchgeführten Experimente in der Simulation zeigen, dass die Korrektur der Wandsegmente auf die Hauptorientierung nur dann sinnvoll ist, falls Fehler in der Orientierungsschätzung des Roboters gering gehalten werden können.

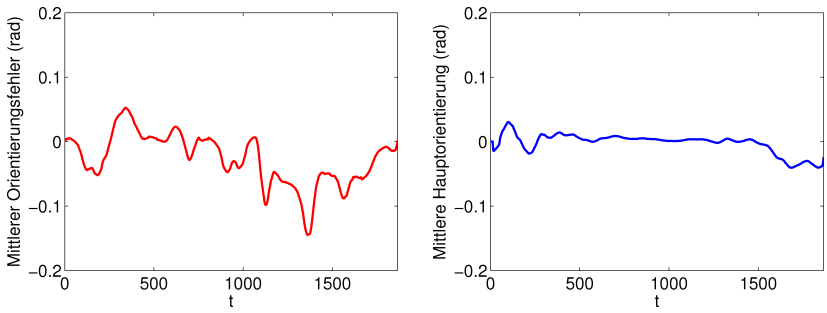

Abbildung 9.12: Mittlerer Orientierungsfehler (links) und mittlere Hauptorientierung (rechts) für das Experiment in Abb. 9.10.b).

a)

b)

c)

d)

Abbildung 9.13: Beispielbilder der Testumgebung mit unmodellierten Begebenheiten. Bild a: Geländer mit durchsichtigen Streben und Spiegelungen in einer Glaswand. Bild b: Hervorstehende Türen und Türrahmen. Bild c: Erzeugtes Zeilenbild aus Bild a. Bild d: Erzeugtes Zeilenbild aus Bild b.

9.2 Experimente in der realen Umgebung

Die Versuche in der realen Umgebung werden in einem Gebäudeflur des Instituts für Informatik an der Universität Freiburg durchgeführt. Abb. 9.14 zeigt einen Grundriss des Gebäudestockwerks. Der Gebäudeflur besitzt Eigenschaften, die den getroffenen Annahmen über die Umgebung nicht entsprechen, wie z.B. ein Geländer mit durchsichtigen Bereichen zwischen den Streben und eine Glaswand, in der die Umgebung gespiegelt wird. In Abb. 9.13 sind Beispielbilder typischer unmodellierter Eigenschaften dargestellt.

In den Versuchen wird eine Kamera auf einem omnidirektionalen Fahrgestell durch die Umgebung bewegt. Die Kamera bewegt sich dadurch parallel zum Fussboden in einer Höhe von 1m und mit einem Nickwinkel von $-23.5°$. Erschwerend für die quantitative Auswertung der Experimente ist die Tatsache, dass keine Information über die tatsächliche Pose des Roboters zur Verfügung steht.

Das Verfahren konnte im Rahmen dieser Arbeit nicht echtzeitfähig implementiert werden. Es werden daher Testdatensätze erzeugt, die Zeilenbilder, Tiefenbilder und aggregierte Messungen des Inertialsensors in einer Rate von 10 Hz beinhalten. In den vorliegenden Experimenten wurden zwei Datensätze, im folgenden als A und B bezeichnet, verwendet, die in der Position a (s. Abb. 9.15) starten, jeweils eine grosse Schleife ($a \rightarrow b \rightarrow c \rightarrow d \rightarrow e \rightarrow a$) um den rechteckigen Gebäudekern und eine kleine Schleife ($c \rightarrow f \rightarrow c$) in den seitlichen Durchgang und zurück in den Hauptflur enthalten. In Testdatensatz A wird die

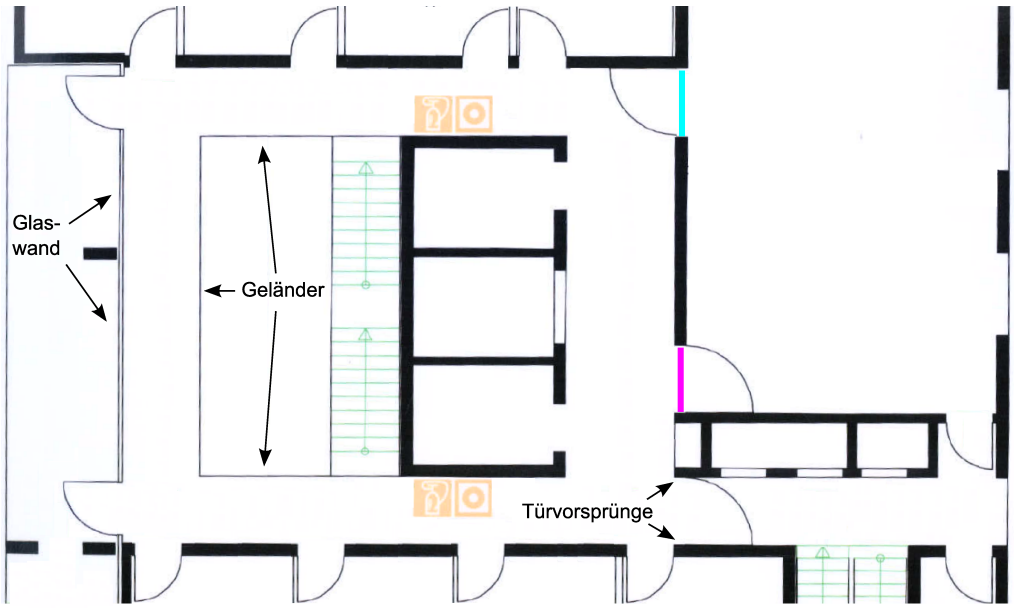

Abbildung 9.14: Grundriss der Testumgebung.

Kamera bis zur Position b bewegt, während Testdatensatz B in einer Position zwischen c und b endet. Die Trajektorien in Testdatensatz A und B besitzen jeweils eine Länge von ca. 70m bzw. 65m. Tabelle 9.3 enthält zur Schilderung des Ablaufs Zeitpunkte, Positionen und grobe Ausrichtung des Roboters in beiden Datensätzen.

9.2.1 Evaluation der Bewegungsschätzung

Im folgenden werden die einzelnen Komponenten zur Bewegungsschätzung untersucht. Abb. 9.16 zeigt Trajektorien, die durch Integration der mittleren geschätzten Geschwindigkeiten in Testdatensatz A entstehen. Die Komponenten der Bewegungsschätzung werden auf unterschiedliche Weise kombiniert.

Ohne Verwendung eines Inertialsensors muss im Zustandsübergangsmodell eine neutrale Beschleunigung ($a_t = 0$) angenommen werden. In Korridoren und aufgrund der Verwendung der Punkt-zu-Geraden Metrik ist im Scanmatching-Verfahren nicht in allen Situationen die Bewegung des Roboters observierbar. Das Verfahren liefert aber eine Kovarianz,

Datensatz A

t	p	θ	t	p	θ
1	a	$\rightarrow$	480	b	$\downarrow$
90	b	$\downarrow$	570	c	$\rightarrow$
190	c	$\leftarrow$	620	f	$\rightarrow$
290	d	$\uparrow$	640	f	$\leftarrow$
375	e	$\rightarrow$	700	c	$\uparrow$
420	a	$\rightarrow$	798	b	$\leftarrow$

Datensatz B

t	p	θ	t	p	θ
1	a	$\rightarrow$	490	b	$\downarrow$
80	b	$\downarrow$	580	c	$\rightarrow$
180	c	$\leftarrow$	610	f	$\rightarrow$
300	d	$\uparrow$	640	f	$\leftarrow$
390	e	$\rightarrow$	680	c	$\uparrow$
450	a	$\rightarrow$			

Tabelle 9.3: Zeitliche Abfolge der Trajektorien in den Testdatensätzen A und B mit groben Positions- und Orientierungsangaben.

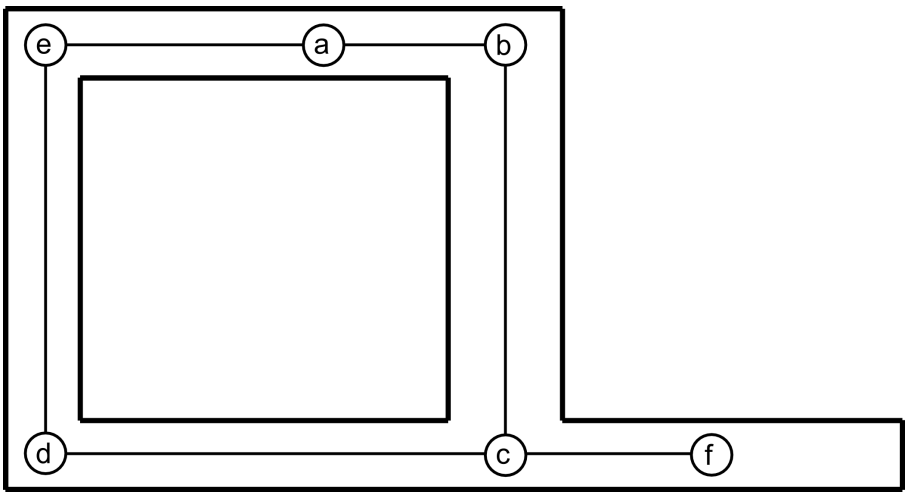

Abbildung 9.15: Traversierter Bereich der Testumgebung mit Positionsmarkierungen.

die hohe Unsicherheit in den nicht observierbaren Dimensionen besitzt. Daher wird die tatsächlich zurückgelegte Wegstrecke unterschätzt, wie in Abb. 9.16.a und b erkennbar ist. Wird zusätzlich ein Inertialsensor verwendet, entsprechen die Abmessungen der Trajektorien (Abb. 9.16.c und d) der tatsächlichen Trajektorie besser.

Die Tiefenbildregistrierung auf die Hauptorientierung wird evaluiert, indem eine feste Hauptorientierungsschätzung $\psi = 0.05$ und $\sigma_\psi = 0.1$ angenommen wird, wie sie in typischen SLAM-Experimenten in Datensatz A geschätzt wird. Die mittleren Trajektorien in Abb. 9.16.b und d zeigen, dass die Korrektur Orientierungsdrift verhindert, und die resultierenden mittleren Trajektorien der tatsächlichen Trajektorie besser entsprechen als ohne Korrektur (Abb. 9.16.a und c).

In einem Experiment wird für unterschiedliche Varianten der Bewegungsschätzung die Posenentropie je Zeitschritt ermittelt, indem 200 Posenstichproben erzeugt werden und die Entropie nach der Methode in Abschnitt 9.1.2 approximiert wird. Dazu wird in jedem Zeitschritt für jede Stichprobe analog zum Partikelfilterverfahren mit dem Verfahren zur Bewegungschätzung eine normalverteilte Posenschätzung generiert, von der eine neue Pose gezogen wird. Die Ergebnisse sind in Abb. 9.17 gegeben. Es ist zu sehen, dass die Registrierung des Tiefenbilds auf die Hauptorientierung (Abb. 9.17.b) die Unsicherheit in der Orientierungsschätzung nahezu konstant hält. Damit steigt auch die Unsicherheit in der kartesischen Position langsamer, sodass insgesamt geringere Unsicherheit in der Posenschätzung besteht als ohne Registrierung des Tiefenbilds (Abb 9.17.a).

Die Resultate legen nahe, für die Bewegungsschätzung im SLAM-Verfahren die Kombination aus Scanmatching, Inertialsensor und Tiefenbildregistrierung mit der Hauptorientierung zu verwenden.

9.2.2 Simultanes Lokalisieren und Kartieren

Das SLAM-Verfahren wird im folgenden an einer exemplarischen Episode mit 200 Partikeln analysiert. Die Observation und Korrektur von Wänden mit Tiefe wird in diesem Experiment nicht verwendet. Die Bewegung wird mit der Kombination aus Scanmatching, Inertialsensor und Tiefenbildregistrierung auf die Hauptorientierung geschätzt. Abb. 9.19

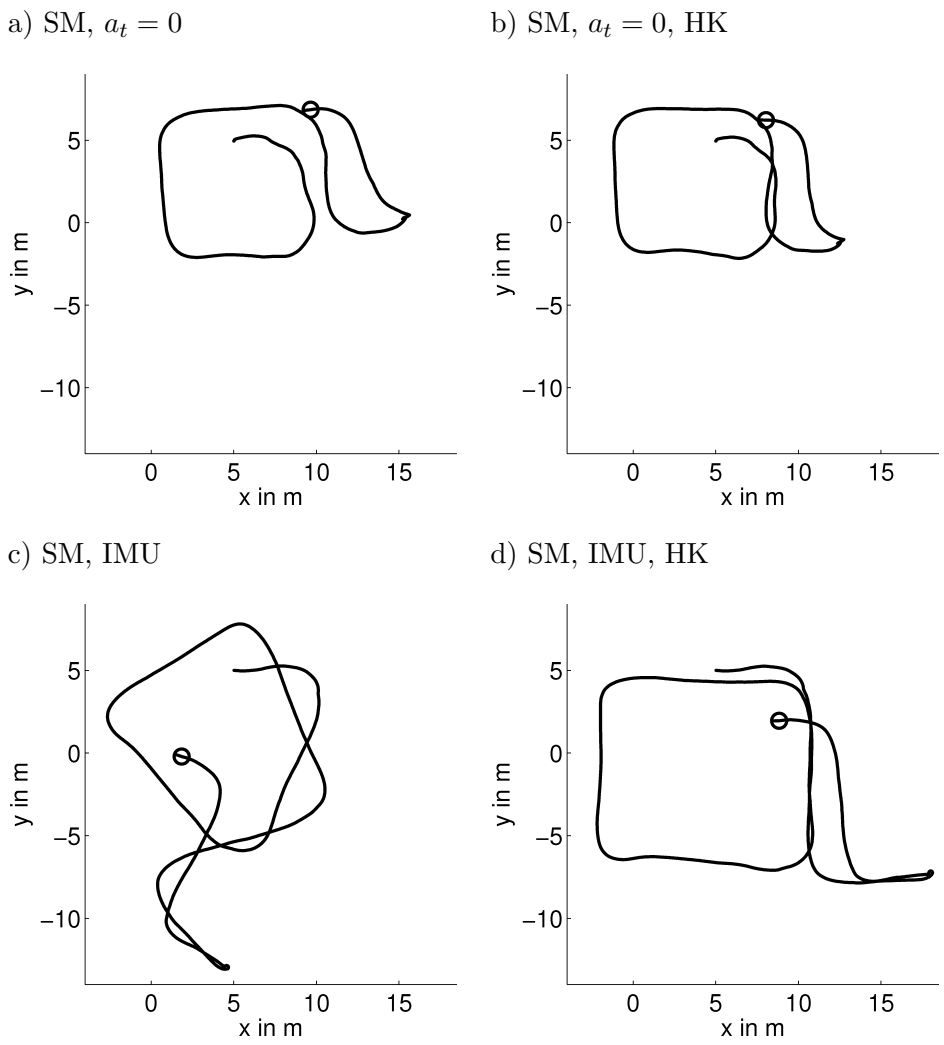

Abbildung 9.16: Mittlere Trajektorien im Testdatensatz A für unterschiedliche Kombinationen der Bewegungsschätzung aus Scanmatching (SM), neutrale Beschleunigung im Zustandsübergangsmodell ($a_t = 0$) bzw. Verwendung eines Inertialsensors (IMU), und Hauptorientierungskorrektur (HK).

und Abb. 9.20 zeigen jeweils Karten- und Trajektorienschätzung vor und nach dem Schliessen der grossen und kleinen Schleife im Testdatensatz A. Bemerkenswert ist, dass trotz der unsicheren und teilweise unterschätzten Tiefenmessungen an weit entfernten Wänden (s. Abb. 9.19.b) eine Karte geschätzt wird, deren Ausmasse den Abmessungen der Testumgebung in guter Näherung entsprechen. Karte und Trajektorie des besten Partikels am Ende der Episode sind in Abb. 9.21.a dargestellt.

Die Entwicklung der Posen- und Trajektorienunsicherheit in Abb. 9.21.b und c zeigt, dass die Unsicherheit bei der Erkundung neuer Kartenbereiche ansteigt. Karten- und Trajektorienschätzung sind ausreichend konsistent, sodass Schleifen geschlossen werden, und die Unsicherheit in Posen- und Trajektorienunsicherheit um die Zeitpunkte $t = 375$ und $t = 620$ sinkt. Die geringe Entropie um den Zeitpunkt $t = 200$ ist dadurch begründet, dass mehrere sicher kartierte Landmarken inklusive der unteren rechten konvexen Ecke des Gebäudekerns über mehrere Zeitschritte in kurzer Distanz observiert werden.

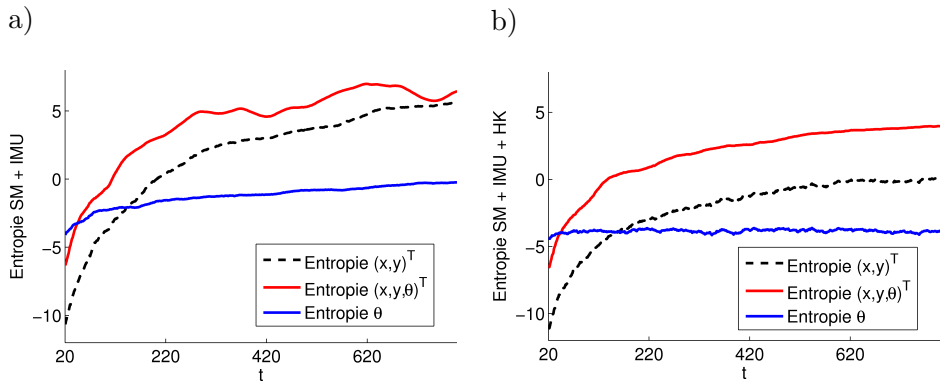

Abbildung 9.17: Entropie in der Posenschätzung für unterschiedliche Verfahren der Bewegungsschätzung im Testdatensatz A. Die einzelnen Abbildungen enthalten Entropie in Pose, kartesischer Position und Orientierung für verschiedene Kombinationen der Einzelverfahren zur Bewegungsschätzung. Bild a: Scanmatching (SM) und Verwendung eines Inertialsensors (IMU). Bild b: Scanmatching (SM), Verwendung eines Inertialsensors (IMU) und Tiefenbildregistrierung mit der Hauptorientierung in der Karte (HK).

In Abb. 9.21.d ist die Anzahl der Partikelmengenerneuerungen seit Episodenbeginn dargestellt. Es werden 228 Partikelmengenerneuerungen in 798 Zeitschritten durchgeführt. Dennoch ist die Diversität in den Trajektorien der Partikel gering, wie beispielsweise in Abb. 9.19.a ersichtlich ist. Fehlerhafte Schätzungen in Datenassoziation, Trajektorie und Karte in frühen Zeitpunkten der Episode sind daher nicht mehr reversibel. Die Schätzungen sind jedoch wie bereits erwähnt ausreichend konsistent, um bereits kartierte Bereiche der Umgebung wiederzuerkennen und Schleifen zu schliessen. Der Verlauf der mittleren Landmarkenanzahl in den Partikelkarten (s. Abb. 9.21.e) belegt, dass bereits kartierte Bereiche der Umgebung wiedererkannt und nicht neu kartiert werden.

Die Anzahl der detektierten Merkmale in Abb. 9.21.f sinkt zeitweise auf geringe Werte, sodass für die Korrektur von Pose und Karte nur wenige Landmarkenobservationen zur Verfügung stehen. Eine weitere Beobachtung ist, dass über die gesamte Episode für einen beträchtlichen Anteil der Merkmale keine Tiefeninformation zur Verfügung steht (s. Abb. 9.21.f). Daher ist es sinnvoll, neben dem Winkel- und Tiefenobservationsmodell auch das reine Winkelobservationsmodell zu verwenden.

Um die Qualität der Karte einzuschätzen, werden Abmessungen in der Umgebung mit Abständen in der Karte verglichen. Abb. 9.18 zeigt tatsächliche und ermittelte Abmessungen in Metern und relative Abweichungen. Die relativen Abweichungen liegen angesichts der ungenauen Tiefenmessungen durchaus in einem guten Bereich. Fehler in der Tiefenmessung entstehen durch unzureichend genaue Kalibrierung des Neigungswinkels der Kamera, ungenaue Modellierung der radialen Verzerrung am Bildrand und Unterschätzung der Tiefe durch fehlerhafte Fussbodensegmentierung in der Ferne. Zudem besitzen Bereiche der Umgebung unmodellierte Eigenschaften, wie bereits erwähnt wurde.

In Tabelle 9.4.a ist die Anzahl an Schleifenschlüsse in jeweils 10 Läufen für unterschiedliche Partikelzahlen im Testdatensatz A angegeben. Die Ergebnisse deuten darauf hin, dass für das zuverlässige Schliessen der grossen und kleinen Schleife bereits 100 Partikel ausreichen. Auffallend ist, dass auch für 200 Partikel die Strecke zwischen Position c und b nicht zuverlässig bewältigt werden kann. Die Probleme an dieser Stelle sind vielfältig:

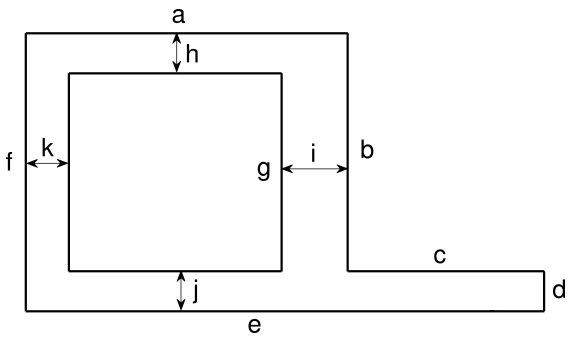

	l	$\tilde{l}$	$\tilde{l}/l$
a	12.12	12.28	1.013
b	8.94	9.33	1.044
c	7.4	6.86	0.927
d	1.5	1.47	0.98
e	19.52	19.7946	1.014
f	10.44	9.595	0.919
g	7.44	7.649	1.028
h	1.5	1.63	1.087
i	2.49	2.489	0.9994
j	1.5	1.67	1.113
k	1.62	1.6810	1.0377

Abbildung 9.18: Tatsächliche (l), geschätzte ($\tilde{l}$) Abmessungen der Testumgebung in m und relative Abweichungen $\tilde{l}/l$ in einem Experiment mit 200 Partikeln im Testdatensatz A.

- Blickt der Roboter entlang von langen Korridoren, liefert das Verfahren zur Tiefenextraktion fehlerhafte Messungen, in denen die Tiefe zum Ende des Korridors unterschätzt wird. Verursacht wird dies durch Spiegelungen im Fussboden, die die Fussbodenfarbe stark verfälschen. Die Assoziation von Landmarken am Ende des Korridors kann deswegen verhindert werden, falls die Fehlmessung eine inkompatible Tiefe zur Landmarke liefert.
- Eine weitere Fehlerquelle ist die geringe Unterscheidbarkeit von Kantenlandmarken an der linken Korridorwand und am Ende des Korridors sowohl im Ort als auch im Deskriptor, falls sich der Roboter in der Position c befindet. Tragen die Partikel ausschliesslich fehlerhafte Datenassoziationshypothesen, führt dies unvermeidlich zur Divergenz des Verfahrens. Bereits geringe Orientierungsfehler beim Schliessen der kleinen Schleife können dies verursachen.
- Die Trajektorienlänge in Abb. 9.16 wird im betroffenen Abschnitt unterschätzt. Die Korrektur dieses Fehlers muss durch die Posenkorrektur im FastSLAM-Verfahren bewerkstelligt werden. Dazu muss eine ausreichende Menge an sicher geschätzten Landmarken observiert werden und eine korrekte Tiefenmessung zur Verfügung ste-

a) Standardverfahren

# Partikel (M)	20	50	100	200
Grosse Schleife	6	9	10	10
Kleine Schleife	9	9	10	9
Ecke	2	2	1	6

b) ohne Posenkorrektur durch Tiefenbildregistrierung

# Partikel (M)	20	50
Grosse Schleife	2	1
Kleine Schleife	0	1
Ecke	0	0

Tabelle 9.4: Anzahl Schleifenschlüsse in 10 Läufen für unterschiedliche Konfigurationen des SLAM-Verfahrens im Testdatensatz A. Tabelle a: Ergebnisse des Standardverfahrens für unterschiedliche Partikelzahlen. Tabelle b: Ergebnisse ohne Posenkorrektur durch Tiefenbildregistrierung für Partikelzahlen $M = 20$ und $M = 50$.

hen.

- Die Umgebung besitzt vor allem an Türen Einbuchtungen. Aus unterschiedlichen Blickwinkeln werden am Übergang zwischen Wand und Tür Kantenmerkmale an Innen- und Aussenseite detektiert, die in beiden Fällen dieselbe Beschreibung besitzen, sich aber im Ort geringfügig unterscheiden. Da die Tiefenmessung mit hoher Unsicherheit behaftet sind, werden sie daher mit derselben Landmarke assoziiert, was ebenfalls zu metrischen Unstimmigkeiten in Karten- und Positionsschätzung führt.

Die Ergebnisse der Experimente mit unterschiedlichen Partikelzahlen weisen darauf hin, dass durch Erhöhung der Partikelzahl und damit der Vielfalt in der Partikelmenge das Auftreten dieses Problems verringert werden kann, was allerdings eine geringere Effizienz nach sich zieht. Insgesamt aber ist klar, dass das Verfahren unter diesen Approximationen und Fehlerquellen kein exaktes, metrisches Ergebnis liefern kann.

Die Nützlichkeit der Posenkorrektur durch Tiefenbildregistrierung auf die Hauptorientierung belegt Tabelle 9.4.b. Mit wenigen Partikeln ist die Zuverlässigkeit ohne Korrektur deutlich geringer als beim Standardverfahren.

Im zweiten Datensatz (B) wurden ebenfalls 10 Läufe mit 200 Partikeln durchgeführt. In allen Läufen wurden grosse und kleine Schleife geschlossen. Die Kartenqualität entspricht der Qualität im Testdatensatz A.

# Partikel (M)	20	200
Grosse Schleife	4	9
Kleine Schleife	10	10
Ecke	2	9

Tabelle 9.5: Anzahl Schleifenschlüsse in 10 Läufen des SLAM-Verfahrens mit Tiefenkorrektur und -observation von Wänden im Testdatensatz A. Die Versuche wurden mit $M = 20$ und $M = 200$ Partikeln durchgeführt.

Für das Verfahren mit Tiefenkorrektur und -observation von Wänden (s. Abschnitt 8.5.5) wurden ebenfalls 10 Läufe in Testdatensatz A mit unterschiedlichen Partikelanzahlen durchgeführt. Die Ergebnisse für 20 und 200 Partikel sind in Tabelle 9.5 aufgeführt.

Die Versuche mit 200 Partikeln deuten darauf hin, dass der Bereich von Wegpunkt c nach b am Ende des Datensatzes zuverlässiger bewältigt werden kann als ohne Observation und Korrektur von Wänden. Es ist zu bemerken, dass geringfügige Unterschätzungen in der Tiefe entlang des Korridors dazu führen, dass die Wand am Ende des Korridors auf die unterschätzte Tiefe korrigiert wird. Andererseits erhalten Partikel eine höhere Observationswahrscheinlichkeit, falls ihre Trajektorie zu Tiefenmessungen führen, die mit dem Wandmodell besser übereinstimmen.

Die Ergebnisse für 20 Partikel lassen keine Aussage über eine Verbesserung oder Verschlechterung des Verfahrens zu.

9.2.3 Globale Lokalisierung

In der Ergebniskarte des vorangegangenen Abschnitts wird evaluiert, ob die Kartenrepräsentation für die globale Lokalisation geeignet ist. Da die tatsächliche Pose des Roboters nicht bekannt ist, kann die mittlere Abweichung in kartesischer Position und

Orientierung nur mit denselben Daten und bezüglich der mittleren Trajektorie im SLAM-Verfahren bestimmt werden.

Zur globalen Lokalisation wird das SLAM-Verfahren ohne Kartierung verwendet, welches einem Monte-Carlo-Lokalisationsverfahren (s. Abschnitt 3.4) mit verbesserter Vorschlagsverteilung entspricht, für die die aktuellen Observationen berücksichtigt werden. Es wird die adaptive Methode in [25] verwendet, in der anhand des Verhältnisses zwischen einem langsamen und einem schnellen mittleren Schätzwert der durchschnittlichen Partikelgewichte über die vergangenen Zeitschritte die Wahrscheinlichkeit bestimmt wird, Partikel durch zufällige Posen im traversierbaren Bereich zu ersetzen. Diese Ersetzung findet nur während einer Partikelmengenerneuerung statt. Die Anzahl der Partikel wird ebenfalls anhand des Verhältnisses linear zwischen 50 und 1000 Partikeln interpoliert, um aus Effizienzgründen zwischen Posenverfolgung und globaler Lokalisation zu wechseln. Befinden sich Partikel ausserhalb des traversierbaren Bereichs, werden sie durch eine zufällige Pose ersetzt.

Die mittlere Pose des Lokalisationsverfahrens wird durch Meanshift [43] ausgehend von der letzten Posenschätzung bestimmt. Falls das Gewicht der Partikel, die zur Bestimmung der Pose verwendet werden, in der Summe gering ist oder keine Posenschätzung besteht, wird das Meanshiftverfahren mit dem besten Partikel initialisiert.

Mit Testdatensatz A werden 10 Läufe durchgeführt. Der mittlere Positions- und Orientierungsfehler ist in Abb. 9.22 dargestellt. Die 25%-, 50%- und 75%-Quantile des Positionsfehlers betragen $0.0317m$, $0.0522m$ und $0.1002m$. Für den Orientierungsfehler ergeben sich die Quantile $0.0049rad$, $0.0096rad$ und $0.0162rad$. Es ist also in guter Näherung möglich, die metrische Pose des Roboters in der ermittelten Karte zu schätzen.

Zwischen den Zeitschritten $t = 300$ und $t = 370$ tritt in 1 von 10 Läufen ein Lokalisationsfehler auf. In dieser Zeitspanne werden bis zu fünf Merkmale pro Bild observiert, von denen mehrere Merkmale keine zuverlässige Tiefenmessung besitzen. Die Merkmale können aufgrund ihrer geringen Diskriminierbarkeit in mehreren Bereichen der Karte assoziiert werden und liefern eine hohe Observationswahrscheinlichkeit. Ab dem Zeitpunkt $t = 370$ besteht dieses Problem nicht mehr und die korrekte Hypothese kann verfolgt werden.

In weiteren Experimenten wird das Lokalisationsverfahren in ausgewählten Zeitpunkten $t \in \{200, 300, 600, 700\}$ gestartet, indem 1000 Partikel uniform im traversierbaren Bereich verteilt werden. Die mittleren Positions- und Orientierungsfehler in Abb. 9.23 zeigen, dass das Lokalisationsverfahren nach wenigen Zeitschritten zu einer korrekten Posenschätzung gelangt.

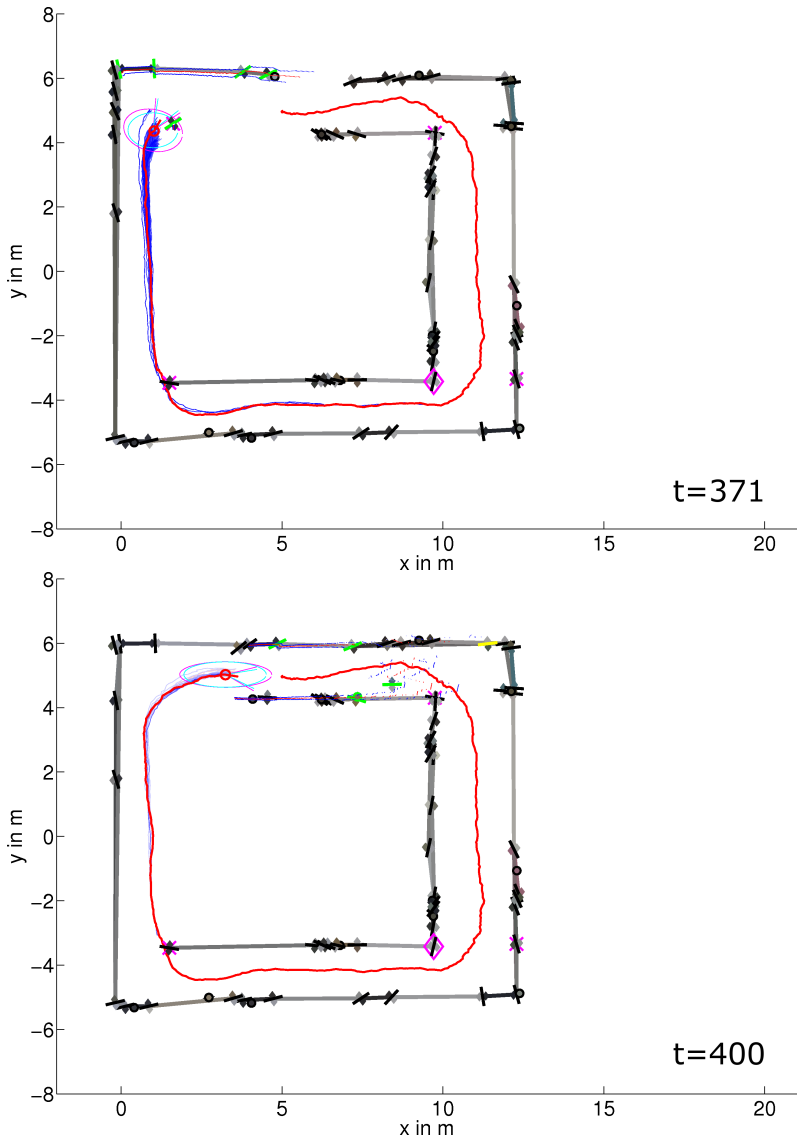

Abbildung 9.19: SLAM-Experiment in der realen Testumgebung mit 200 Partikeln in ausgewählten Zeitpunkten jeweils vor und nach dem Schliessen einer Schleife. Es werden Karte und Trajektorie (rot) des Partikels mit aktuell höchstem Gewicht dargestellt. Die Trajektorien der übrigen Partikel werden umso blauer dargestellt, je höher ihr Gewicht ist. Grün visualisierte Landmarken werden durch den Roboter observiert. Gelbe Landmarken werden im aktuellen Zeitschritt initialisiert. Die aktuellen Tiefenmessungen sind als rote Punkte mit blauen Standardabweichungen (mit $\sigma_{d,0}^2 = 0$) dargestellt. Die Unsicherheiten in initialer (magenta) und korrigierter (cyan) Posenschätzung sind als 30σ-Umgebungen um ihren Mittelwert gegeben.

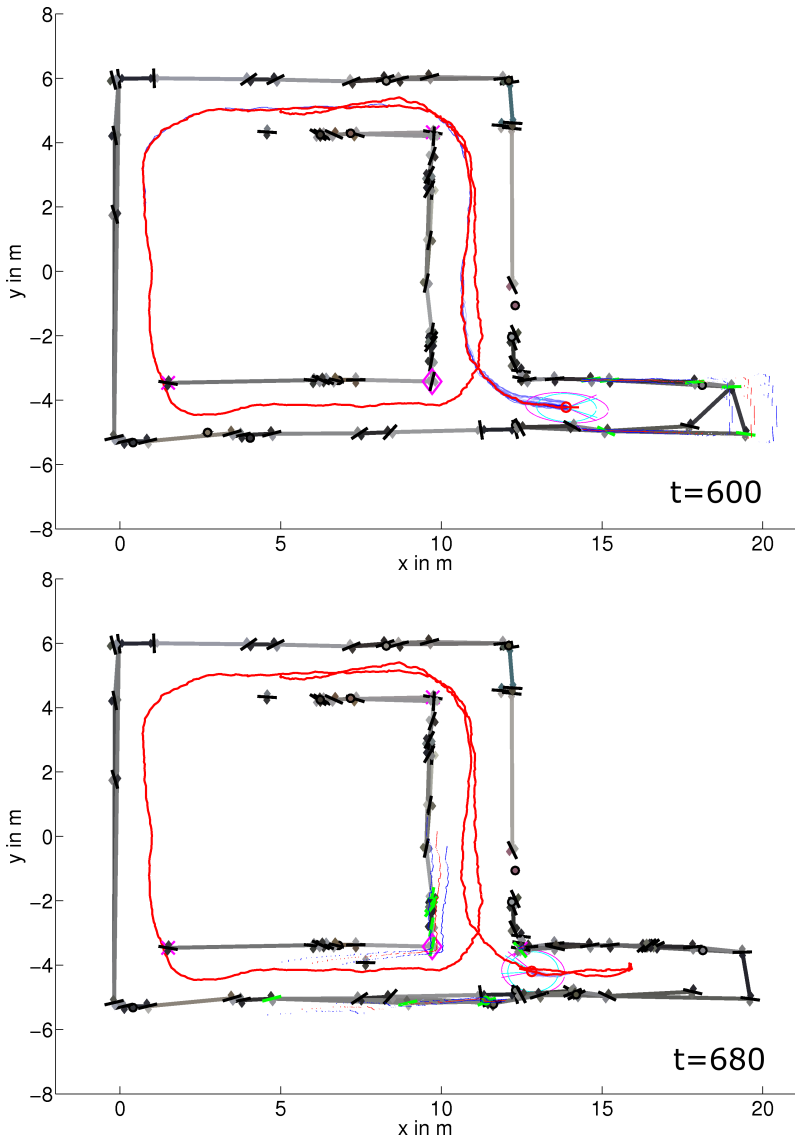

Abbildung 9.20: SLAM-Experiment in der realen Testumgebung mit 200 Partikeln in ausgewählten Zeitpunkten jeweils vor und nach dem Schliessen einer Schleife. Es werden Karte und Trajektorie (rot) des Partikels mit aktuell höchstem Gewicht dargestellt. Die Trajektorien der übrigen Partikel werden umso blauer dargestellt, je höher ihr Gewicht ist. Grün visualisierte Landmarken werden durch den Roboter observiert. Gelbe Landmarken werden im aktuellen Zeitschritt initialisiert. Die aktuellen Tiefenmessungen sind als rote Punkte mit blauen Standardabweichungen (mit $\sigma_{d,0}^2 = 0$) dargestellt. Die Unsicherheiten in initialer (magenta) und korrigierter (cyan) Posenschätzung sind als 30σ-Umgebungen um ihren Mittelwert gegeben.

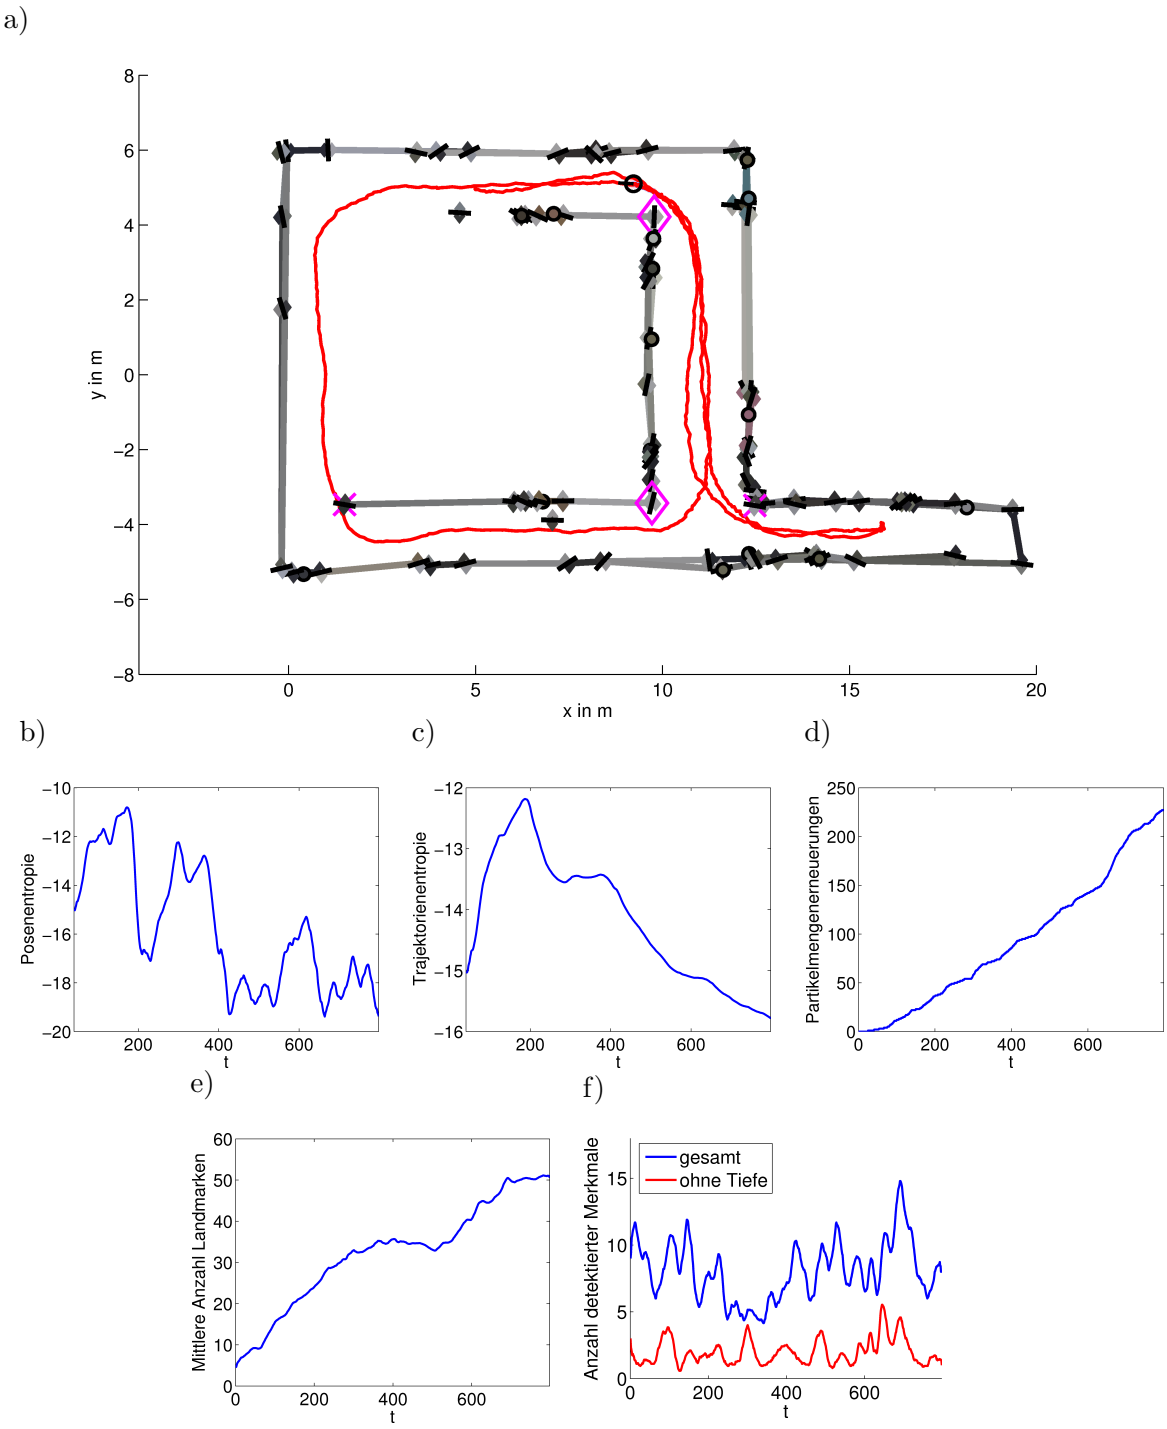

Abbildung 9.21: Ergebnisse eines SLAM-Experiments in der realen Testumgebung mit 200 Partikeln. Bild a: Karte und Trajektorie (rot) des besten Partikels im letzten Zeitschritt. Bild b: Posenentropie der Partikelmenge. Bild c: Trajektorienentropie der Partikelmenge. Bild d: Anzahl an Erneuerungen der Partikelmenge seit Episodenbeginn. Bild e: Mittlere Anzahl an Landmarken in den Partikelkarten. Bild f: Anzahl an detektierten Merkmalen (blau) und Anzahl an Merkmalen ohne Tiefenmessung (rot).

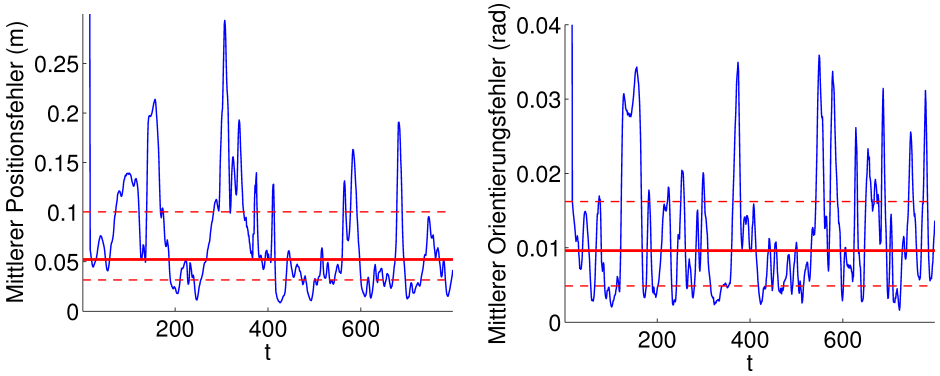

Abbildung 9.22: Mittlerer Positions- (links) und Orientierungsfehler (rechts) während der globalen Lokalisierung mit Testdatensatz A. Der Median der Abweichungen ist rot dargestellt. Die 25%- und 75%-Quantile werden rot gestrichelt visualisiert. Metrische Lokalisation ist in der geschätzten Karte möglich.

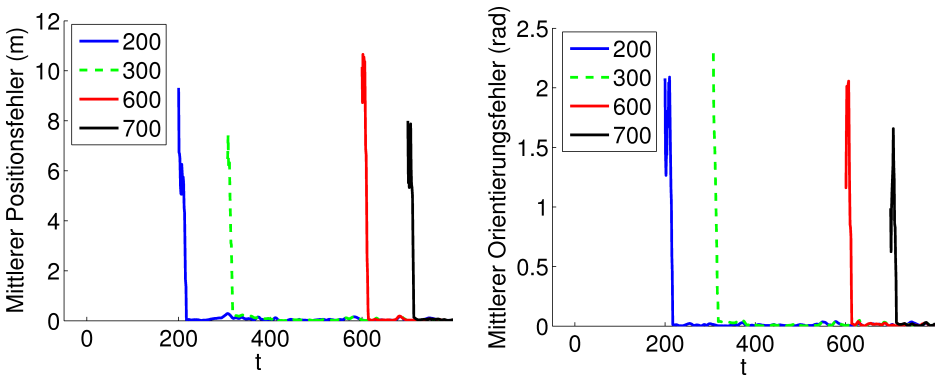

Abbildung 9.23: Mittlerer Positions- (links) und Orientierungsfehler (rechts) während der globalen Lokalisierung mit Testdatensatz A. Das Verfahren wird in den Zeitpunkten $t \in \{200, 300, 600, 700\}$ initialisiert. Das Lokalisationsverfahren gelangt nach wenigen Zeitschritten zu einer korrekten Posenschätzung.

10 Zusammenfassung

In dieser Arbeit wurde das simultane Lokalisieren und Kartieren mit einer einzelnen Kamera untersucht, für das typische Eigenschaften von Innenräumen ausgenutzt und repräsentiert werden. Es wird eine zweidimensionale Umgebungsrepräsentation gelernt, die die Wandstruktur der Umgebung als geradlinige Verbindungen zwischen punktförmigen Landmarken modelliert. Unter der Annahme, dass die wesentlichen Strukturen der Umgebung in zwei Dimensionen beschrieben werden können, und da sich die Kamera nur in der horizontalen Ebene bewegt, kann die Umgebungsstruktur kompakt in eindimensionalen Bildern beobachtet werden.

In diesen eindimensionalen Bildern werden Merkmale der Umgebungsstruktur extrahiert und als Observationen von Landmarken im SLAM-Verfahren aufgefasst. Durch Bewegungsparallaxe wird der Ort dieser Landmarken in einem globalen Koordinatensystem bestimmt und die Trajektorie des Roboters in dieser Karte simultan geschätzt.

Kantenlandmarken existieren an Grenzen von gleichförmigen Umgebungsstrukturen. Unter der Annahme, dass Wände planar sind, wurden sie als geradlinige Verbindungen von Kanten modelliert. Die Überprüfung einer Reihe von Kriterien führt zu positiven und negativen Sichtungen von Wandsegmenten, sodass deren Existenz rekursiv geschätzt werden kann.

Das Wandmodell bietet die Möglichkeit, Tiefe in Bereichen zwischen verknüpften Landmarken zu inferieren. Ohne direkte Messung von Tiefe können dadurch Datenassoziation und Kartierung im SLAM-Verfahren verbessert werden, beispielsweise durch die Überprüfung auf Verdeckungen oder durch die Verwendung als Tiefenhinweis bei der Initialisierung von Landmarken. Sind Wände in der Umgebung parallel oder orthogonal, kann die Hauptorientierung der Umgebung aus den kartierten Wandsegmenten bestimmt werden. Es wurde untersucht, ob eine Registrierung der Wandsegmente auf die geschätzte Hauptorientierung möglich ist, indem die unterstützenden Landmarken der Wandsegmente in ihrer Position angepasst werden.

Experimente in der Simulation zeigen, dass das Verfahren in der Lage ist, die Wandstruktur der Umgebung bei bekannter Pose akkurat zu kartieren. Auch bei einer geringen Anzahl von fünf bis 20 Observationen pro Bild, kann SLAM mit Bewegungsinformationen zuverlässig durchgeführt werden. Für die Registrierung des Wandmodells auf die Hauptorientierung zeigte sich, dass deren Verwendung zur Laufzeit des SLAM-Verfahrens nur sinnvoll ist, falls Orientierungsdrift in der Trajektorienschätzung verhindert werden kann.

Bei der Übertragung des Ansatzes in die reale Umgebung stand zunächst keine Bewegungsinformation zur Verfügung. Im Vergleich zur Simulation werden pro Bild eine noch geringere Anzahl an Merkmalen extrahiert, die durch unmodellierte Gegebenheiten der Testumgebung teilweise inkonsistente Winkelmessungen liefern. Ausserdem wird die Skala der metrischen Rekonstruktion von Pose des Roboters und Struktur der Umgebung bei der ausschliesslichen Verwendung von reinen Winkelmessungen zu einem freien Parameter. Dadurch wurde es notwendig, zusätzliche Informationsquellen zu erschliessen.

Dazu wurde eine weitere typische Eigenschaft von Innenräumen ausgenutzt, in denen

der Fussboden meist visuell trennbar von der restlichen Umgebung gestaltet ist. In der Testumgebung besitzt der Boden eine markante Farbe, wodurch die Segmentierung des Fussbodens möglich ist. Da die Kamera sich in einer horizontalen Ebene bewegt, sind Kamerahöhe und Neigungswinkel bekannt und Tiefe kann am Übergang von Fussboden zu Wänden geschätzt werden. Zusätzlich wurde der Roboter mit einem Inertialsensor ausgestattet, um seine Bewegung zu erfassen.

Mit den Tiefenmessungen kann zunächst das SLAM-Verfahren in Datenassoziation, Observationsmodell, und Wandstrukturschätzung verbessert werden. Da Tiefenmessungen nicht zuverlässig im gesamten Bildbereich extrahiert werden können, werden reine Winkelmessungen und Winkel- und Tiefenmessungen im SLAM-Verfahren simultan unterstützt. Saliente Merkmale im Tiefenbild werden zusätzlich zu den visuellen Merkmalen extrahiert, um visuell nicht trennbare Strukturen erfassen zu können. Es wurde ausserdem untersucht, wie am Wandmodell Tiefe observiert und das Wandmodell mit Tiefenmessungen korrigiert werden kann.

Bewegungsinformationen werden aus den Tiefenmessungen durch Scanmatching geschätzt, um die Drift der Geschwindigkeitsschätzung mit dem Inertialsensor zu korrigieren. Ist die Hauptorientierung der Umgebung bekannt, wird zusätzlich gefordert, dass die Wandsegmente im Tiefenbild in der Pose des Roboters dieser Hauptorientierung folgen. Dadurch ist es auch in unexplorierten Bereichen möglich, die geschätzte Karte zur Einschränkung der Unsicherheit in der Orientierung des Roboters zu verwenden. Damit reduziert sich die Trajektorienschätzung des Roboters im wesentlichen auf die Schätzung ihrer kartesischen Koordinaten.

In Experimenten wurde belegt, dass mit dem Verfahren eine Karte der Umgebung geschätzt werden kann, die trotz der unsicheren, unzuverlässigen und teilweise fehlerhaften Messungen in guter Näherung mit den Abmessungen der realen Umgebung übereinstimmt. Das Wandmodell weist dort Fehlstellen und Lücken auf, wo die Umgebung den getroffenen Annahmen nicht genügt. Experimente zur Lokalisation zeigen, dass globale, metrische Lokalisation mit dem vorgestellten Verfahren in einer geschätzten Karte möglich ist.

10.1 Beiträge dieser Arbeit

- Es wurde ein Verfahren zur simultanen Lokalisation und Kartierung vorgestellt, in dem ausgehend von kompakten, eindimensionalen Bildmessungen landmarkenbasierte Repräsentationen von Innenräumen gelernt werden. Durch die Verbindung von Landmarken durch Wände entsteht eine abstraktere Darstellung für Navigation und Lokalisation als bei rein landmarkenbasierten Ansätzen. Es wurden Methoden vorgestellt, mit denen das SLAM-Verfahren in Datenassoziation, Lokalisation und Kartierung durch die Verwendung des Wandmodells erweitert wird.
- Zur Schätzung der omnidirektionalen Bewegung einer Kamera in der horizontalen Ebene wurde eine Methode entwickelt, welche die Messungen eines Inertialsensors und Bewegungsschätzung aus visuellen Tiefenmessungen kombiniert. Die Orthogonalität und Parallelität von Wänden in Innenräumen wird ausgenutzt, um die Orientierungsschätzung der Kamera zu verbessern, indem die beobachteten Wandsegmente im Tiefenbild auf die geschätzte Hauptorientierung in der Karte registriert werden.

- Unterschiedliche Informationsquellen über die Umgebungsstruktur wurden in kompakter Weise fusioniert und verwendet. Merkmale der Umgebungsstruktur in der horizontalen Ebene, die in eindimensionalen Bildern detektiert werden und somit reine Winkelobservationen darstellen, werden mit Tiefe versehen, die visuell aus der Umgebungsstruktur entlang der Vertikalen extrahiert wird. Zusätzlich werden in den Tiefenbildern saliente Merkmale der Umgebungsstruktur wie Tiefensprünge oder konvexe und konkave Ecken extrahiert, die anschliessend mit Zeilenbildmerkmalen fusioniert werden.
- Da visuelle Tiefe nicht zuverlässig zur Verfügung steht, wurde eine Formulierung vorgestellt, in der sowohl reine Winkelobservationen als auch Winkel- und Tiefenobservationen unterstützt werden. Dadurch ist es möglich, die zur Verfügung stehenden Observationen pro Bild vollständig auszunutzen.

10.2 Diskussion

Das vorgestellte SLAM-Verfahren ist in der Lage, die Wandstruktur von solchen Innenräumen zu kartieren, die den getroffenen Annahmen über die Umgebung entsprechen. Die Verwendung in einem realen Innenraumszenario zeigte, dass das Verfahren auch bei Abweichungen von diesen Annahmen ein gutes Ergebnis liefert. Die Anwendung auf allgemeinere Umgebungen wird vor allem durch Inkompatibilitäten in Tiefen- und Winkelmessungen eingeschränkt, die in der Unterschiedlichkeit der Informationsgewinnung begründet sind.

Das vorgestellte System enthält eine Vielzahl von Heuristiken und Parametern, für die eine sinnvolle Einstellung bestimmt werden muss. Während einige Parameter, insbesondere die Parameter der Observationsmodelle, datenspezifisch sind, ist ein Grossteil durch die Anwendung vorgegeben und kann dauerhaft sinnvoll eingestellt werden. Das SLAM-Verfahren wurde durch heuristische Methoden wie Registrierung des Wandmodells auf die Hauptorientierung und Tiefenobservation und -korrektur von Wänden erweitert, sodass die Eigenschaften der Umgebung und die zur Verfügung stehenden Informationen möglichst gut ausgenutzt werden.

Strukturen in der Umgebung erscheinen nicht nur in unterschiedlichen Skalen im Bild, sondern auch in unterschiedlichen Repräsentationen als Merkmale. Wandsegmente werden aus der Nähe als gleichförmige Bereiche zwischen zwei begrenzenden Kanten beobachtet. Erscheint der Bereich zwischen den Kanten aus grösserer Entfernung ausreichend klein, wird zusätzlich im Wandsegment ein Blobmerkmal detektiert. In grosser Entfernung zum Wandsegment, kann es entweder nicht mehr observiert werden, da die Struktur zu beiden Seiten des Segments eine ähnliche Beschaffenheit besitzt, oder es wird an ihrer Stelle eine Kante detektiert. Dieses Problem wird in dieser Arbeit durch Sichtbarkeitskonzepte wie z.B. die Erwartung einer minimalen Skala von Kantenmerkmalen gelöst, die am Wandmodell abgeleitet wird. Die Umgebungsstruktur ist dadurch in mehreren Skalenstufen in der Karte repräsentiert. Eine andere Lösung dieses Skalenproblems, z.B. durch Assoziation korrespondierender Merkmale, könnte zu einer kompakteren Darstellung der Karte führen.

Für Navigation und Lokalisation sind Karten vorteilhaft, die nicht nur Punkte ohne räumliche Ausdehnung enthalten, sondern auch Wände. Das Wandmodell kann die Planung von sinnvollen Pfaden in der metrischen Karte ermöglichen. Wird an Wänden Tiefe oder

Helligkeits- und Farbbeschaffenheit gemessen, kann die Lokalisation in der Abwesenheit von punktförmigen Landmarkenobservationen verbessert werden.

Es wurden Konzepte zur Sichtbarkeit von Landmarken vorgestellt, die falsche Assoziationen verhindern. Die Möglichkeit von Verwechslungen ist durch fehlende Tiefeninformation, durch die geringe Diskriminierbarkeit der Landmarken und durch die Reduktion des Problems auf zwei Dimensionen begründet. Es konnte in dieser Arbeit nicht geklärt werden, inwiefern die erhöhten Laufzeitkosten, insbesondere für die Überprüfung auf Verdeckungen durch das Wandmodell, in der Praxis gerechtfertigt sind. In drei Dimensionen würde die zusätzliche Bildkoordinate eventuell die nötige Information bieten, um hohe Robustheit in der Datenassoziation ohne aufwändige Sichtbarkeitskonzepte zu gewährleisten.

Ein wesentlicher Vorteil von landmarkenbasierten Ansätzen gegenüber gridbasierten Lösungen des SLAM-Problems ist die Spärlichkeit der erzeugten Karten und die Effizienz der Verfahren, die auf diesen Karten beruhen. Durch die Erweiterung von punktbasierten Landmarkenkarten durch Wände können zwar auch Bereiche zwischen Landmarken modelliert werden, jedoch bringt dieser Ansatz erhöhte Kosten in Datenassoziation, Observation und Kartenverwaltung mit sich, z.B. bei der Überprüfung von Landmarkenverdeckungen. Gerade bei einem partikelfilterbasierten Ansatz, in dem eine Vielzahl von Kartenhypothesen verwaltet wird, kann dies nachteilig sein.

Die Überprüfung auf Verdeckungen von Landmarken durch das Wandmodell bietet auch Vorteile, da die Anzahl der sichtbaren Landmarken reduziert wird. Dadurch müssen nur wenige Landmarken im lokalen Sichtbereich für die Datenassoziation in Betracht gezogen werden, was die Effizienz des Verfahrens erhöht.

Die Messung von Tiefe am Fussbodensegment ist für mobile Systeme nützlich, für die die Lage des Bildsensors bekannt ist. Für die Kamera am Kopf eines humanoiden Roboters beispielsweise ist dies nur in grober Näherung gegeben, sofern keine Stabilisierung der Kamera während der Fortbewegung möglich ist. Die Verwendung eines Inertialsensors zur Bestimmung der Kameraneigung könnte das Problem beseitigen.

10.3 Ausblick

Diese Arbeit wurde mit der Absicht erstellt, die Möglichkeit eines visuellen SLAM-Verfahrens zu erkunden, das die wesentlichen Strukturen von Innenräume in drei Dimensionen kartiert. Dazu sind Verfahren in einem breiten Spektrum von der Extraktion von Merkmalen in der Umgebungsstruktur bis hin zur Aggregation und Verwaltung von punkt-, linien- und flächenbasierten Kartenelementen zu entwickeln. Eine mögliche Weiterentwicklung könnte die Übertragung des vorgestellten zweidimensionalen Verfahrens auf ein Verfahren in drei Dimensionen sein.

Die Wahl eines FastSLAM-Verfahrens zur Schätzung von Trajektorie und Karte ist durch die Überlegenheit gegenüber eines EKF-Verfahrens bei der Kartierung einer hohen Anzahl an Landmarken und durch die Möglichkeit, mehrere Datenassoziationshypothesen verfolgen zu können, motiviert. Es stellte sich im Rahmen dieser Arbeit heraus, dass die Verwendung des Wandmodells auf Partikelbasis mit hohen Laufzeitkosten verbunden ist. Um dennoch einen Rao-Blackwellisierten Ansatz zur Schätzung von Trajektorie und Karte zu verfolgen, müssten effiziente Algorithmen für die Verwendung und Verwaltung des wandbasierten Umgebungsmodells entwickelt werden.

Die Verwendung einer einzelnen Kamera liegt darin begründet, dass ein starres, kalibri-

ertes Mehrkamerasichtsystem auf der Zielplattform, einem humanoiden Roboter, nicht zur Verfügung steht. Die Benutzung eines Mehrkamerasichtsystems würde ein Verfahren in drei Dimensionen mit direkteren Tiefenobservationen erheblich vereinfachen. Der Roboter besitzt Kameras mit ausreichend Disparität, die allerdings während des Betriebes für die multimodale Kommunikation bewegt werden und mechanisch nicht exakt justiert sind. Es ist denkbar, eine extrinsische Kalibrierung für die möglichen Konfigurationen der Zielpositionen der Kameras zu lernen.

Um den Ansatz in der reduzierten Dimensionalität auf allgemeinere Umgebungen zu übertragen, sind eine Reihe von Erweiterungen notwendig. Vor allem Inkompatibilitäten von Tiefen- und Winkelmessungen aus der vertikalen und horizontalen Informationsquelle müssen zuverlässig erkannt werden. Die gleichzeitige Positionsschätzung von Landmarken sowohl durch reine Winkelobservationen als auch durch Winkel- und Tiefenobservationen könnte die Erkennung einer solchen Diskrepanz ermöglichen. Eine weitere Möglichkeit, zuverlässigere und kompatiblere Tiefe zu erhalten, wäre die Verwendung eines Laser-Entfernungssensors, der in einer ähnlichen Ebene Tiefe misst, in der auch das Zeilenbild extrahiert wird.

Die gewählte Art der Merkmalsdetektion und -beschreibung ist heuristisch und enthält eine Vielzahl von manuell eingestellten Parametern. In Anlehnung an die menschliche Wahrnehmung könnten an dieser Stelle Methoden des maschinellen Lernens verwendet werden, um in einer geeigneten Repräsentation des Bildes automatisiert Merkmale zu detektieren. Mit ähnlichen Methoden könnten Datenassoziation und Aggregation von punktförmigen Landmarken zu Wänden erfolgen, sodass der direkte Vergleich von expliziten Helligkeits- und Farbwerten vermieden werden kann. Beleuchtungsinvarianz der Merkmale wäre ebenfalls ein mögliches Ziel einer Weiterentwicklung.

Eine reichhaltigere Beschreibung von Merkmalen kann die Datenassoziation erheblich verbessern. Die Verwendung von Textur wäre eine Möglichkeit, Merkmale diskriminativer zu beschreiben. Werden Wände durch ihre Texturierung beschrieben, muss die Entfernungs- und Blickwinkelabhängigkeit aufgrund der projektiven Abbildung berücksichtigt werden.

Für die Navigation ist ein autonomes mobiles System nicht auf metrisch exakte Karten angewiesen, die eine vollständige Beschreibung der Arbeitsumgebung enthalten. Es ist vorstellbar, ein Wandmodell in einem lokal eingeschränkten Bereich zu erzeugen, das zur Pfadplanung bzw. Hindernisvermeidung in diesem Bereich verwendet wird. In einem topologischen SLAM-Ansatz könnten weitere Abstraktionen der lokalen Umgebungsrepräsentationen wie z.B. Flure, Durchgänge und Räume verwendet werden, um Orientierung und Navigation in grösserem Maßstab zu ermöglichen.

Literaturverzeichnis

[1] D. G. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2):91–110, 2004.

[2] S. Se, D. G. Lowe, and J. J. Little. Mobile robot localization and mapping with uncertainty using scale-invariant visual landmarks. *International Journal of Robotic Research*, 21(8):735–760, 2002.

[3] P. S. Maybeck. *The Kalman Filter: An Introduction to Concepts*, pages 194–204. Springer, 1990.

[4] T. D. Barfoot. Online visual motion estimation using FastSLAM with SIFT features. In *Proceedings of the IEEE International Conference on Robots and Systems (IROS)*. IEEE, 2005.

[5] M. Montemerlo, S. Thrun, D. Koller, and B. Wegbreit. FastSLAM 2.0: An improved particle filtering algorithm for simultaneous localization and mapping. In *Eighteenth International Joint Conference on Artificial Intelligence (IJCAI)*, Acapulco, Mexico, 2003.

[6] R. Sim, P. Elinas, M. Griffin, A. Shyr, and J. J. Little. Design and analysis of a framework for real-time vision-based SLAM using rao-blackwellised particle filters. In *Proceedings of the The 3rd Canadian Conference on Computer and Robot Vision (CRV'06)*, page 21, Washington, DC, USA, 2006.

[7] P. Elinas, R. Sim, and J. J. Little. σslam: Stereo vision SLAM using the rao-blackwellised particle filter and a novel mixture proposal distribution. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pages 1564–1570, Orlando, Florida, 2006.

[8] N. Karlsson, E. D. Bernardo, J. Ostrowski, L. Goncalves, P. Pirjanian, and M. E. Munich. The vSLAM algorithm for robust localization and mapping. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pages 24–29, Barcelona, 2005.

[9] L. Goncalves, E. D. Bernardo, D. Benson, M. Svedman, J. Ostrowski, N. Karlsson, and P. Pirjanian. A visual front-end for simultaneous localization and mapping. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pages 44–49, Barcelona, 2005.

[10] M. Montemerlo, S. Thrun, D. Koller, and B. Wegbreit. FastSLAM: A factored solution to the simultaneous localization and mapping problem. In *Proceedings of the AAAI National Conference on Artificial Intelligence*, Edmonton, Canada, 2002. AAAI.

[11] A. J. Davison. Real-time simultaneous localization and mapping with a single camera. In *Proceedings of the International Conference on Computer Vision*, 2003.

[12] J. Shi and C. Tomasi. Good features to track. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 593–600, 1994.

[13] J. M. M. Montiel, J. Civera, and A. J. Davison. Unified inverse depth parametrization for monocular SLAM. In *Proceedings of Robotics: Science and Systems II (RSS)*, Philadelphia, Pennsylvania, 2006.

[14] E. Eade and T. Drummond. Scalable monocular SLAM. In *Proceedings of the 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 469–476, Washington, DC, USA, 2006.

[15] P. Smith, I. Reid, and A. Davison. Real-time monocular SLAM with straight lines. In *Proceedings of the 17th British Machine Vision Conference (BMVC)*, Edinburgh, 2006.

[16] E. Eade and T. Drummond. Edge landmarks in monocular SLAM. In *Proceedings of the 17th British Machine Vision Conference (BMVC)*, pages 7–16, Edinburgh, 2006.

[17] A. Briggs, Y. Li, D. Scharstein, and M. Wilder. Robot navigation using 1D panoramic images. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pages 2679–2685, Orlando, Florida, 2006.

[18] A. Briggs, C. Detweiler, P. Mullen, and D. Scharstein. Scale-space features in 1D omnidirectional images. In *Omnivis 2004, the fifth Workshop on Omnidirectional Vision (in conjunction with ECCV 2004)*, pages 115–126, Prague, Czech Republic, 2004.

[19] A. Briggs, Y. Li, and D. Scharstein. Feature matching across 1D panoramas. In *Omnivis 2005, the sixth Workshop on Omnidirectional Vision (in conjunction with ICCV 2005)*, Beijing, China, 2005.

[20] S. Lenser and M. Veloso. Visual sonar: Fast obstacle avoidance using monocular vision. In *Proceedings of the IEEE-RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2003.

[21] Y. Choi and S. Oh. Visual sonar based localization using particle attraction and scattering. In *Proceedings of the IEEE International Conference on Mechatronics and Automation*, volume 1, pages 4495–454, Niagara Falls, Canada, 2005.

[22] V. Nguyen, A. Harati, N. Tomatis, A. Martinelli, and R. Siegwart. Orthogonal SLAM: a step toward lightweight indoor autonomous navigation. In *Proceedings of the IEEE-RSJ International Conference on Intelligent Robots and Systems (ICRA)*, 2006.

[23] P. Jensfelt, H.I. Christensen, and G. Zunino. Integrated systems for mapping and localization. In J. Leonard and H. Durrant-Whyte, editors, *ICRA-02 SLAM Workshop*. IEEE, 2002.

[24] R. E. Kalman. A new approach to linear filtering and prediction problems. *Trans-*

actions of the ASME, Journal of Basic Engineering, 82:34–45, 1960.

[25] S. Thrun, W. Burgard, and D. Fox. *Probabilistic Robotics.* MIT Press, 2005.

[26] G. Grisetti, C. Stachniss, and W. Burgard. Improving grid-based SLAM with rao-blackwellized particle filters by adaptive proposals and selective resampling. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA).* IEEE, 2005.

[27] A. Doucet. On sequential simulation-based methods for bayesian filtering. Technical Report CUED/F-INFENG/TR. 310, Cambridge University Department of Engineering, 1998.

[28] G. R. Cowell, A. P. Dawid, S. L. Lauritzen, and D. J. Spiegelhalter. *Probabilistic Networks and Expert Systems.* Springer-Verlag, New York, 1999.

[29] Y. Bar-Shalom. *Tracking and data association.* Academic Press Professional, Inc., San Diego, CA, USA, 1987.

[30] J. Neira and J. D. Tardos. Data association in stochastic mapping using the joint compatibility test. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA).* IEEE, 2001.

[31] A. J. Davison, Y. G. Cid, and N. Kita. Real-time 3D SLAM with wide-angle vision. In *Proceedings of the 5th IFAC/EURON Symposium on Intelligent Autonomous Vehicles*, Lisboa, Portugal, 2004.

[32] T. Lindeberg and L. Bretzner. Real-time scale selection in hybrid multi-scale representations. In *Springer Lecture Notes in Computer Science*, volume 2695, pages 148–163, 2003.

[33] T. Lindeberg. Scale-space for discrete signals. In *IEEE Transactions of Pattern Analysis and Machine Intelligence*, pages 234–254. IEEE, 1990.

[34] C. G. Harris and M. Stephens. A combined corner and edge detector. In *Proceedings of the 4th Alvey Vision Conference*, pages 147–151, 1988.

[35] K. Mikolajczyk and C. Schmid. Scale and affine invariant interest point detectors. *International Journal of Computer Vision*, 60(1):63–86, 2004.

[36] H. Bay, T. Tuytelaars, and L. Van Gool. SURF: Speeded up robust features. In *Proceedings of the 9th European Conference on Computer Vision*, 2006.

[37] M. A. Fischler and R. C. Bolles. A paradigm for model fitting with applications to image analysis and automated cartography. In *Communications of the ACM*, volume 24, pages 381–395, 1981.

[38] T. Lemaire, S. Lacroix, and J. Sol. A practical bearing-only SLAM algorithm. In *Proceedings of the IEEE International Conference on Intelligent Robots and Systems (IROS)*, Edmonton, Canada, 2005. IEEE.

[39] J. Klippenstein, H. Zhang, and X. Wang. Feature initialization for bearing only visual SLAM using triangulation and the unscented transform. In *Proceedings of the IEEE*

International Conference on Mechatronics and Automation (ICMA), Harbin, China, 2007. IEEE.

[40] J. Civera, A. J. Davison, and J. M. M. Montiel. Inverse depth to depth conversion for monocular SLAM. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, April 2007.

[41] Y. Bar-Shalom and X. R. Li. *Estimation and Tracking: Principles, Techniques and Software*. Artech House, 1993.

[42] P. Piniés, T. Lupton, S. Sukkarieh, and J. D. Tardós. Inertial aiding of inverse depth SLAM using a monocular camera. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2007.

[43] D. Comaniciu and P. Meer. Mean shift: A robust approach toward feature space analysis. volume 24, pages 603–619, Los Alamitos, CA, USA, 2002. IEEE Computer Society.

[44] R. I. Hartley and A. Zisserman. *Multiple View Geometry in Computer Vision*. Cambridge University Press, 2000.

[45] D. C. Brown. Close-range camera calibration. *Photogrammetric Engineering*, 37:855–866, 1971.

[46] J. Bouguet. Camera calibration toolbox for matlab. http://www.vision.caltech.edu/bouguetj/calib_doc/, Abruf: 01.09.2007.

[47] A. Rosenfeld, R. Hummel, and S. Zucker. Scene labeling by relaxation operations. In *IEEE Transactions on Systems, Man and Cybernetics*, volume 6, pages 420–433, 1976.

[48] P. Besl and N. McKay. A method for registration of 3-D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2):239–256, 1992.

[49] A. Censi. An accurate closed-form estimate of ICP's covariance. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pages 3167–3172. IEEE, 2007.

[50] C. Stachniss, G. Grisetti, and W. Burgard. Information gain-based exploration using rao-blackwellized particle filters. In *Proceedings of Robotics: Science and Systems (RSS)*, Cambridge, MA, USA, 2005.

[51] N. Roy, W. Burgard, D. Fox, and S. Thrun. Coastal navigation – mobile robot navigation with uncertainty in dynamic environments. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, Detroit, MI, May 1999.

[52] K. O. Arras. An introduction to error propagation: Derivation, meaning and examples of Cy = Fx Cx Fx'. Technical Report EPFL-ASL-TR-98-01 R3, Autonomous Systems Lab, Swiss Federal Institute of Technology Lausanne, 1998.

A Verwendete Hardware

Abbildung A.1: Links: IDS uEye UI-1226LE Kamera mit Weitwinkelobjektiv. Rechts: Xsens MTi Inertialsensor.

A.1 Kamera mit Weitwinkelobjektiv

Die IDS uEye UI-1226LE Kamera ist für industrielle Anwendungen konzipiert und ist mit einem 1/3“ CMOS Sensor ausgestattet. Über eine USB2.0 Schnittstelle werden Bilder mit einer maximalen Bildrate von 87 Hz in einer WVGA-Auflösung mit 752×480 Bildpunkten geliefert. Ein extremes Weitwinkelobjektiv ermöglicht einen Blickwinkelbereich von 140°×90°.

A.2 Inertialsensor

Der MTi Inertialsensor der Firma Xsens Motion Technologies verfügt über lineare Beschleunigungs-, Drehraten- und Magnetfeldsensoren auf drei orthogonalen Achsen. Ein Mikroprozessor verarbeitet die rohen Sensordaten vor und liefert kalibrierte lineare Beschleunigungen, biaskorrigierte Drehraten und die dreidimensionale Orientierung des Sensors über eine RS-232 Schnittstelle mit einer Frequenz von 100 Hz.

B Extraktion von Tiefenmerkmalen

Für die Extraktion der Tiefenmerkmale wird das Tiefenbild in kartesische Koordinaten transformiert. In K äquidistanten Abtastpunkten wird innerhalb eines Fensters F fester Länge nach Tiefenmerkmalen gesucht. Durch sämtliche kartesische Punkte $\mathcal{X} := \{X_k = (x_k, y_k)^T\}_{k=1}^K$ innerhalb des Fensters wird eine Gerade $\gamma : x\cos(\alpha) + y\sin(\alpha) - r = 0$ in Hessischer Parametrisierung approximiert [52]:

$$\begin{aligned}
\mu_{\mathcal{X}} &:= \frac{\sum_{k=1}^K w_k X_k}{\sum_{k=1}^K w_k} \\
n_{\mathcal{X}} &:= -2\sum_{k=1}^K w_k (y_k - \mu_{\mathcal{X},y})(x_k - \mu_{\mathcal{X},x}) \\
d_{\mathcal{X}} &:= \sum_{k=1}^K w_k ((y_k - \mu_{\mathcal{X},y})^2 - (x_k - \mu_{\mathcal{X},x})^2) \\
\alpha &= \frac{1}{2} arctan2(n, d) \\
r &= \mu_{\mathcal{X},x}\cos(\alpha) + \mu_{\mathcal{X},y}\sin(\alpha)
\end{aligned} \tag{B.1}$$

Als Gewichte w_k werden die Detektionssicherheiten der Tiefenobservationen verwendet. Falls das durchschnittliche Gewicht der Observationen im Fenster kleiner als ein Schwellwert ist, stehen nicht genügend zuverlässige Tiefenobservationen zur Verfügung und die Suche im aktuellen Fenster wird abgebrochen.

Es soll in der Punktmenge $\mathcal{X}$ ein Spaltpunkt $X_{\check{k}}$ mit maximaler Abweichung zur approximierten Gerade bestimmt werden. Ist die gewichtete mittlere quadratische Abweichung E der Punkte von der approximierten Gerade im Vergleich zur Linienlänge l hoch, wird die weitere Behandlung des Fensters abgebrochen, da der Spaltpunkt nicht zuverlässig bestimmt werden kann. Die mittlere quadratische Abweichung ist gegeben als

$$E := \sqrt{\frac{\sum_{k=1}^K w_k (x_k\cos(\alpha) + y_k\sin(\alpha) - r)^2}{\sum_{k=1}^K w_k}}$$

Die Linienlänge wird als Abstand zwischen minimaler und maximaler Projektion der Punkte in $\mathcal{X}$ auf die Gerade γ approximiert.

Die Punkte in $\mathcal{X}$ sind wegen der Abtastung nach Sichtwinkel entlang von Umgebungsstrukturen angeordnet. Wird der Spaltpunkt am Rand ($\check{k} < b$ bzw. $\check{k} > K - b$) der Punktmenge gefunden, kann in der kleineren Punktmenge keine zuverlässige Geradenapproximation bestimmt werden. Daher wird die Punktmenge um den Rand bis zum Spaltpunkt verringert und erneut eine Gerade durch die verbleibenden Punkte in $\mathcal{X}' := \{X_k\}_{k=\check{k}}^K$ bzw. $\mathcal{X}' := \{X_k\}_{k=1}^{\check{k}}$ approximiert, falls die mittlere Detektionssicherheit der Punkte überhalb eines Schwellwerts liegt. Ansonsten wird die Suche im Fenster

abgebrochen. Der Spaltpunkt wird in der zweiten Iteration in der Punktmenge bestimmt, die aus $\mathcal{X}'$ durch Auslassung der Punkte im Randbereich der Länge b hervorgeht, um zu gewährleisten, dass der Spaltpunkt im Inneren des Fensters liegt.

Die Punktmenge $\mathcal{X}$ bzw. $\mathcal{X}'$ wird in eine linke und rechte Punktmenge, $\mathcal{X}_{left}$ und $\mathcal{X}_{right}$, am Spaltpunkt getrennt, wobei eine feste Anzahl an Punkten um den Spaltpunkt nicht berücksichtigt wird. Liegt die mittlere Detektionssicherheit einer der Punktmengen unterhalb eines Schwellwerts, wird die Suche im aktuellen Fenster abgebrochen. Durch die Punktmengen werden die Geraden γ_{left} und γ_{right} approximiert. Falls für eine Gerade das Verhältnis von gewichteter mittlerer quadratischen Abweichung zur Linienlänge überhalb eines Schwellwerts liegt, wird versucht, eine bessere Geradenapproximation in einer verkleinerten Punktmenge am Spaltpunkt zu bestimmen. Die Punktmenge $\mathcal{X}_{left}$ bzw. $\mathcal{X}_{right}$ wird hierzu auf der gegenüberliegenden Seite zum Spaltpunkt reduziert, damit kleinere Umgebungsstrukturen am Spaltpunkt erfasst werden können. Die Punkte werden um die Hälfte der Anzahl an Punkten reduziert, falls die Anzahl der verbleibenden Punkte b beträgt, um eine ausreichende Anzahl an Punkten für eine Geradenapproximation zu erhalten. Falls das mittlere Gewicht in der reduzierten Punktmenge ausreichend gross ist und die darin approximierte Gerade ein besseres Verhältnis von mittlerer quadratischer Abweichung zur Linienlänge liefert als γ_{left} bzw. γ_{right}, wird sie im weiteren Verlauf als Gerade auf der entsprechenden Seite verwendet.

Am Spaltpunkt wurde eine feste Anzahl an Punkten ausgelassen, da an Tiefensprüngen Tiefenmessungen zwischen den Sprungtiefen auftreten können, und so die approximierten Geraden verfälscht werden. Daher werden nach der Approximation von Geraden auf beiden Seiten des Spaltpunkts die Punktmengen erweitert. Ausgehend vom Rand der Punktmengen werden solange Punkte hinzugenommen, bis der Spaltpunkt erreicht ist, der Punkt nicht mehr auf der approximierten Gerade liegt oder der kartesische Abstand zum letzten untersuchten Punkt gross ist. Letzteres ist motiviert durch Tiefensprünge, die im spitzen Winkel observiert werden. In den erweiterten Punktmengen werden die Geraden auf den entsprechenden Seiten erneut approximiert.

Damit innerhalb des Fensters ein Tiefenmerkmal detektiert werden kann, muss mindestens eine Gerade eine gute Approximation sein, d.h. für eine Gerade muss das Verhältnis von mittlerer quadratischer Abweichung zur Linienlänge klein sein. Zunächst wird für die nächsten Punkte am Spaltpunkt in den beiden Punktmengen der Abstand zwischen den Projektionen auf die zugehörige Gerade bestimmt. Sind beide Geraden gut approximiert und ist der Abstand der Projektionen gering, wird überprüft, ob in der Nähe des Spaltpunkts eine konvexe bzw. konkave Ecke vorliegt. Andernfalls werden Bedingungen für einen Tiefensprung am Spaltpunkt geprüft.

a. Überprüfung auf konvexe und konkave Ecken: Unter der Annahme, dass Wände in der Umgebung orthogonal oder parallel sind, wird gefordert, dass der Winkel zwischen den approximierten Geraden im Idealfall $\frac{\pi}{2}$ beträgt. Die Detektionssicherheit c_{ortho} der potentiellen Kante ergibt sich durch lineare Interpolation gemäß der Abweichung von $\frac{\pi}{2}$ zwischen zwei Schranken. Aus dem Schnittpunkt der Geraden zu beiden Seiten wird der Ort der Ecke bestimmt. Durch Projektion in das Bild und anschliessende radiale Verzerrung nach dem Linsenverzerrungsmodell aus Abschnitt 4.3 wird der Ort des Merkmals im Bild mit Subpixelgenauigkeit berechnet. Merkmale am Bildrand werden verworfen, da Tiefe in diesem Bereich aufgrund der

starken radialen Verzerrung im zweidimensionalen Kamerabild nicht zuverlässig ist und auch visuelle Merkmale nicht am Bildrand detektiert werden. Der Abstand des Schnittpunkts der Geraden zum Ursprung liefert die Tiefe zum Merkmal.

An kurzen Tiefensprüngen kann mit der bisherigen Methode eine fälschliche Detektion einer Ecke auftreten, falls das Wandsegment vor dem Tiefensprung orthogonal zum Wandsegment nach dem Tiefensprung ist. Daher wird überpüft, ob der maximale Abstand zwischen benachbarten Punkten in einer lokalen Nachbarschaft der Ecke gering ist. Der Index k_{corner} der Ecke in der Punktmenge $\mathcal{X}$ ist durch den gerundeten Ort des Merkmals im Bild gegeben. Mit diesem maximalen Abstand wird die Detektionssicherheit $c_{discont}$ durch Interpolation zwischen zwei Schranken berechnet. Die Detektionssicherheit c_{edge} des Kantenmerkmals ergibt sich aus dem Minimum aus c_{ortho} und $c_{discont}$. Beträgt sie Null, wird das Merkmal verworfen.

Die Konvexität bzw. Konkavität der Ecke wird festgestellt, indem zusätzlich zu den nächstgelegenen Punkten am Spaltpunkt auch die entferntesten Punkte in beiden Punktmengen auf die zugehörige Gerade projiziert werden. Seien $p_{left,start}$ und $p_{right,start}$ die entferntesten, und seien $p_{left,end}$ und $p_{right,end}$ die nächstgelegensten projizierten Punkte zum Spaltpunkt. Die Richtungsvektoren $v_{left} := p_{left,start} - p_{left,end}$ und $v_{right} := p_{right,end} - p_{right,start}$ berücksichtigen die Anordnung der Punkte nach aufsteigendem Sichtwinkel. Das Vorzeichen des Kreuzprodukts $c(v_{left}, v_{right}) := v_{right,x} v_{left,y} - v_{right,y} v_{left,x}$ liefert einen Indikator für die Konvexität ($c(v_{left}, v_{right}) < 0$) bzw. Konkavität ($c(v_{left}, v_{right}) > 0$) der Ecke.

Die Skala der Kante entspricht der minimalen Ausdehnung der geradlinigen Wandsegmente auf beiden Seiten der Ecke im Tiefenbild. Um sie zu bestimmen, werden für beide Seiten ausgehend vom nächstgelegenen Punkt in der Punktmenge der Seite zum Spaltpunkt die Punkte bis zum Bildrand durchlaufen, bis eine signifikante Abweichung von der approximierten Gerade auftritt. Für einen Punkt wird der Abstand zur approximierten Gerade mit der Detektionssicherheit der Tiefenobservation gewichtet. Beim Durchlaufen der Punkte wird der gewichtete Abstand nach Abzug einer zulässigen Abweichung zu einer Gesamtabweichung akkumuliert. Die Gesamtabweichung wird dabei nach unten durch Null beschränkt. Liegt sie oberhalb eines Schwellwerts, wird die Suche abgebrochen. Für den zuletzt betrachteten Punkt wird mit dem Kamera- und Linsenverzerrungsmodell aus Abschnitt 4.3 der Ort im Bild bestimmt. Auf diese Weise können wenige Ausreisser keinen vorzeitigen Abbruch der Suche verursachen. Die Skala der Kante ergibt sich aus dem minimalen quadratischen Abstand des Orts der Ecke von den Orten der ermittelten Punkt zu beiden Seiten der Ecke.

b. Überprüfung auf Tiefensprünge: Die Punktemengen zu beiden Seiten werden von Ausreissern befreit, indem von den K Punkten in der Punktmenge jeder Seite $O = \max(0, \min(K - b, 0.1K))$ Punkte mit größtem Abstand zur approximierten Gerade entfernt werden. Es sollen also nach der Entfernung der Ausreisser mindestens b Punkte erhalten bleiben. Falls die mittlere Detektionssicherheit in einer der Punktmengen unterhalb eines Schwellwerts liegt, wird das Merkmal verworfen. Ansonsten werden in den neuen Punktmengen erneut Geraden approximiert.

In den Punktmengen müssen die Ausgangspunkte des Tiefensprungs ermittelt werden. Zwischen diesen Punkten sind Tiefenobservationen möglich. Vor allem an

Tiefensprüngen, für die eines der zugehörigen Wandsegmente im spitzen Winkel observiert wird, können Punkte im Sprung entlang der approximierten Gerade liegen. Wurde die Gerade einer Seite ausreichend gut approximiert, wird deshalb ausgehend vom Spaltpunkt durch die Menge der Punkte bis zum äußersten Punkt in der Punktmenge der Seite iteriert, bis ein Punkt gefunden wurde, dessen Vorgänger einen geringen Abstand zum betrachteten Punkt besitzt und der einen geringen Abstand zur approximierten Gerade besitzt. Der ermittelte Punkt wird mit $X_{\bar{k},left}$ bzw. $X_{\bar{k},right}$ bezeichnet.

Ist die Gerade einer Seite schlecht approximiert, wurde für die andere Seite ein Punkt am Tiefensprung ermittelt, da mindestens eine Gerade eine gute Approximation ist. Für die schlecht approximierte Seite wird derjenige Punkt $X_{\bar{k},left}$ bzw. $X_{\bar{k},right}$ bestimmt, der minimalen Abstand zur Projektion des Punkts am Tiefensprung der anderen Seite besitzt.

Die Tiefensprungkante soll auf derjenigen Seite detektiert werden, deren Ausgangspunkt am Tiefensprung die geringste Entfernung zum Ursprung besitzt. Die ermittelten Ausgangspunkte für jede Seite werden in der Norm verglichen. Ist der Ausgangspunkt einer Seite näher, deren Gerade schlecht approximiert wurde, wird das Merkmal verworfen. Andernfalls wird für den potentiellen Tiefensprung überprüft, ob der Sichtwinkel auf die approximierte Gerade auf der nahen Seite ausreichend gross ist, um den Ausgangspunkt zuverlässig zu bestimmen. Mit der Differenz zwischen Sichtwinkel und Orientierung der Geraden wird die Detektionssicherheit c_{LoS} durch lineare Interpolation zwischen zwei Schranken ermittelt.

Ein weiteres Kriterium für eine sichere Detektion ist eine signifikante Weite des Tiefensprungs. Um die Weite zu bestimmen, müssen zwei Fälle unterschieden werden. Im ersten Fall wurde die Gerade auf der entfernteren Seite des Tiefensprungs gut approximiert. Ausgehend vom ermittelten Ausgangspunkt der entfernteren Seite wird für eine Teilmenge der Punkte auf der dem Spaltpunkt abgewandten Seite die Projektion auf die Sichtlinie zum Ausgangspunkt auf der nahen Seite berechnet. Der minimale Abstand der Projektionen zum Ausgangspunkt auf der nahen Seite wird als Weite des Tiefensprungs verwendet. Falls die Gerade auf der entfernteren Seite schlecht approximiert ist, werden sämtliche Punkte in der Punktmenge der entfernteren Seite auf die Sichtlinie zum Ausgangspunkt auf der nahen Seite projiziert. Die Weite des Tiefensprungs wird mit dem minimaler Abstand der Projektionen zum Ausgangspunkt auf der nahen Seite approximiert. Die Detektionssicherheit $c_{discont}$ ergibt sich mit der Tiefensprungweite durch lineare Interpolation zwischen zwei Schranken.

Je kleiner das Verhältnis zwischen Tiefensprungweite und Entfernung des Ausgangspunkts vom Ursprung ist, desto wahrscheinlicher ist es, dass die Detektion von einer varianten Tiefenmessung verursacht wird. Daher wird aus dem Verhältnis durch Interpolation zwischen zwei Schranken die Detektionssicherheit c_{ratio} berechnet.

Auf der nahen Seite müssen benachbarte Punkte in einer lokalen Nachbarschaft des Ausgangspunkts auf der vom Spaltpunkt abgewandten Seite kleine Abstände besitzen. Das Kriterium soll gewährleisten, dass am Ausgangspunkt auf der vom Spaltpunkt abgewandten Seite ein Wandsegment observiert wurde. Aus dem min-

imalen Abstand in der lokalen Nachbarschaft erhält man die Detektionssicherheit c_{cont} durch Interpolation zwischen zwei Schranken.

Die Detektionssicherheit der Tiefensprungkante ergibt sich aus dem Minimum der einzelnen Detektionssicherheiten, $c_{edge} = \min\{c_{LoS}, c_{discont}, c_{ratio}, c_{cont}\}$. Beträgt die Detektionssicherheit Null, wird das Merkmal verworfen.

Der kartesische Ort des Tiefensprungs befindet sich im Schnittpunkt der Sichtlinie zum Ausgangspunkt mit der approximierten Geraden auf der nahen Seite. Für eine bessere Lokalisation des Schnittpunkts wird die Gerade auf der nahen Seite durch die Punktmenge der Seite approximiert, die um diejenigen Punkte reduziert wurde, die näher am Spaltpunkt liegen als der Ausgangspunkt. Bildort und Tiefe des Tiefensprungs ergibt sich durch Projektion des kartesischen Orts in das Bild und anschliessende Verzerrung bzw. als Abstand des kartesischen Orts zum Ursprung. Zusätzlich wird für die Tiefensprungkante die Information über die nahe Seite gespeichert.

Die Skala der Tiefensprungkante wird in analoger Weise zur Skala von konvexen bzw. konkaven Ecken bestimmt. Es wird allerdings nur die zum Ursprung nächstgelegene Seite betrachtet.

Durch das Bestimmen von Tiefenmerkmalen innerhalb von Fenstern an äquidistanten Abtastpunkten können Tiefenmerkmale mehrfach detektiert werden. Ähnliche Tiefenmerkmale desselben Typs werden daher mit ihrer Detektionssicherheit gewichtet in Ort, Skala und Tiefe gemittelt. Die Skala der Merkmale wird auf die nächstgelegene Skala in der Bildpyramide gerundet. In Abb. 8.6 sind Beispiele für die Bestimmung von Merkmalskandidaten und detektierte Tiefenmerkmale dargestellt.

Tiefenmerkmale treten an Grenzen von Wandsegmenten auf und entsprechen daher visuellen Kantenmerkmalen. Es ist möglich, dass visuelle Merkmale und Tiefenmerkmale an derselben Kante in der Umgebung detektiert werden. Damit nicht mehrere Observationen derselben Landmarke in einem Zeitschritt beobachtet werden, müssen korrespondierende Merkmale fusioniert werden. Jedes Tiefenmerkmale wird mit dem kompatibelsten visuellen Merkmal fusioniert, indem der Ort der Merkmale im Bild mit der Detektionssicherheit gewichtet gemittelt wird. Die Skala des fusionierten Merkmals ergibt sich aus dem Minimum der Skalen der Merkmale. Die Detektionssicherheit berechnet sich aus dem Mittel der Detektionssicherheiten der fusionierten Merkmale. Die Kompatibilität zweier Merkmale m und m' in den Orten p_m bzw. $p_{m'}$ und auf den Skalen t_m bzw. $t_{m'}$ berechnet sich als

$$comp_{fuse}(m, m') := -\frac{(p_m - p_{m'})^2}{(\min\{t_m, t_{m'}\})}$$

Liegt die beste Kompatibilität unterhalb eines Schwellwerts, werden die Merkmale nicht fusioniert. Das fusionierte Kantenmerkmal wird wie visuelle Kantenmerkmale mit der Methode in Abschnitt 5.4 beschrieben.