



Hochschule für Angewandte Wissenschaften Hamburg  
*Hamburg University of Applied Sciences*

# **Master-Thesis**

**Lennart Bartelt**

**Indoor Positionierung mit Smartphones auf Basis vorhandener  
Infrastruktur**

*Fakultät Technik und Informatik  
Studiendepartment Informatik*

*Faculty of Engineering and Computer Science  
Department of Computer Science*

Lennart Bartelt

**Indoor Positionierung mit Smartphones auf Basis vorhandener  
Infrastruktur**

Master-Thesis eingereicht im Rahmen der Masterprüfung

im Studiengang Master of Science Informatik  
am Department Informatik  
der Fakultät Technik und Informatik  
der Hochschule für Angewandte Wissenschaften Hamburg

Betreuender Prüfer: Prof. Dr. Kai von Luck  
Zweitgutachter: Prof. Dr. Bettina Buth

Eingereicht am: 14. Februar 2017

**Lennart Bartelt**

**Thema der Arbeit**

Indoor Positionierung mit Smartphones auf Basis vorhandener Infrastruktur

**Stichworte**

Indoor Positionierung, Smartphone, Infrastrukturfreie Lokalisierung, Smart Home, Ubiquitous Computing, GPS, Mobilfunk, Magnetometer, Koppelnavigation, Gyroskop, Optisches Tracking, Barometer, Schallortung, Schrittzähler, Triangulation, Trilateration, Fingerprinting, Absolute Ortung, Relative Ortung, SLAM, Sensor-Fusion, Nearest Neighbor Filterung, Kalman-Filter, Partikel-Filter, Clustering, Creative Space, Living Place

**Kurzzusammenfassung**

Diese Arbeit beschreibt die Positionierung von Smartphones in Innenräumen. Hierbei werden die Sensoren Mobilfunk, WiFi, Bluetooth sowie Magnetometer fusioniert und deterministische Positionierungsverfahren, speziell das Fingerprinting, angewandt. Die Messergebnisse werden mit einem gewichteten k-Nearest Neighbors Filter gefiltert und in Praxistests auf ihre Eignung hin untersucht.

**Lennart Bartelt**

**Title of the paper**

Indoor positioning with smartphones based on existing infrastructure

**Keywords**

Indoor Positioning, Smartphone, Infrastructure-less Localization, Smart Home, Ubiquitous Computing, GPS, Mobile Radio, Magnetometer, Dead-Reckoning, Gyroscope, Optical Tracking, Barometer, Sound Localization, Pedometer, Triangulation, Trilateration, Fingerprinting, Absolute Positioning, Relative Positioning, SLAM, Sensor-Fusion, Nearest Neighbor Filtering, Kalman-Filter, Particle-Filter, Clustering, Creative Space, Living Place

**Abstract**

This document describes the positioning of smartphones in indoor environments. For this the mobile radio, WiFi, Bluetooth and magnetometer sensors get fused and deterministic positioning techniques are used, with fingerprinting in particular. The measurements get filtered with a weighted k-Nearest Neighbors filter and tested for their applicability.

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
<b>2</b>	<b>Sensorik eines Smartphones</b>	<b>7</b>
2.1	GPS, Mobilfunk und FM . . . . .	8
2.2	WiFi und Bluetooth . . . . .	10
2.3	Magnetfelder . . . . .	13
2.4	Beschleunigung und Orientierung . . . . .	17
2.5	Optische Ortung . . . . .	19
2.6	Barometer . . . . .	21
2.7	Schall . . . . .	22
<b>3</b>	<b>Positionierungsverfahren und Filterungsarten</b>	<b>26</b>
3.1	Absolute Ortung . . . . .	27
3.1.1	Triangulation und Trilateration . . . . .	27
3.1.2	Fingerprinting . . . . .	29
3.2	Relative Ortung . . . . .	34
3.3	SLAM . . . . .	37
3.4	Sensor-Fusion . . . . .	41
3.5	Filterung . . . . .	47
3.5.1	Nearest Neighbor . . . . .	48
3.5.2	Kalman-Filter . . . . .	52
3.5.3	Partikel-Filter . . . . .	54
3.6	Clustering . . . . .	56
<b>4</b>	<b>IndoorGPS</b>	<b>61</b>
4.1	Architektur . . . . .	61
4.2	Optimierungen . . . . .	64
4.2.1	Filterung . . . . .	64
4.2.2	Messreduktion bei inaktivem Schrittzähler . . . . .	64
4.2.3	Verwerfen entfernter Messungen . . . . .	65
4.2.4	Lineare Abschwächung . . . . .	66
4.2.5	Dynamische Sensorgewichtung . . . . .	67
4.3	Nutzung . . . . .	68
4.4	Messungen . . . . .	71
4.4.1	Zu beantwortende Fragen . . . . .	71
4.4.2	Experimentaufbauten und Versuchsorte . . . . .	72

4.4.3	Ergebnisse der Messungen im HAW Gebäude . . . . .	78
4.4.4	Ergebnisse der Messungen im Creative Space . . . . .	82
4.4.5	Ergebnisse der Messungen im Living Place . . . . .	82
4.5	Zwischenfazit und technischer Ausblick . . . . .	84
<b>5</b>	<b>Fazit und Ausblick</b>	<b>88</b>

# Tabellenverzeichnis

4.1	Ergebnisse der Messungen im 11. OG des HAW Gebäudes . . . . .	80
4.2	Ergebnisse des Vergleichs IndoorGPS / ARTTRACK im Creative Space . . . . .	83
4.3	Ergebnisse der Messungen im Living Place . . . . .	84

# Abbildungsverzeichnis

1.1	Vereinfachte Darstellung eines Smart Homes . . . . .	4
2.1	Im Smartphone verbaute Sensoren . . . . .	7
2.2	Empfang von GPS- und Mobilfunksignalen innerhalb von Gebäuden . . . . .	8
2.3	Ortung im Bürokomplex mit WiFi und Bluetooth . . . . .	11
2.4	Abfolge einer Kundenkommunikation per Bluetooth-Beacon . . . . .	13
2.5	Simulierte Darstellung von Magnetfeldsignaturen . . . . .	14
2.6	Einfluss von Umweltfaktoren auf das gemessene Magnetfeld 1 . . . . .	16
2.7	Einfluss von Umweltfaktoren auf das gemessene Magnetfeld 2 . . . . .	16
2.8	Unterteilung von auf Accelerometer basierenden Ortungssystemen . . . . .	18
2.9	Positionierung anhand optischer Orientierungspunkte . . . . .	20
2.10	Einblenden der Wegpunkte in das Kamerabild . . . . .	20
2.11	Druckverteilung über die Etagen eines Hochhauses . . . . .	21
2.12	Ortung eines Smartphones durch eigenes Ultraschallsignal . . . . .	23
2.13	Fusion der Sensordaten bei SurroundSense . . . . .	23
2.14	Amplitudenbasierte Fingerabdrücke dreier Umgebungen . . . . .	24
3.1	Triangulation und Trilateration . . . . .	28
3.2	Vereinfachte Darstellung des Fingerprintings . . . . .	30
3.3	Wahrscheinlichkeitsverteilung eines Funksignals . . . . .	32
3.4	Funktionsweise der Koppelnavigation . . . . .	35
3.5	Driftkorrektur nach Loop Close . . . . .	35
3.6	Ablauf der Verfahrensauswahl bei SmartSLAM . . . . .	39
3.7	Typischer Aufbau einer Crowd Sourcing SLAM-Lösung . . . . .	41
3.8	Aufteilung der Arten der Sensorintegration nach Ruser und León . . . . .	42
3.9	Erweiterung und Verrechnung der Signal-Vektoren bei der Sensor-Fusion . . . . .	44
3.10	Unterschied zwischen euklidischer und Manhattan-Distanz . . . . .	45
3.11	Auswirkung von K auf das Ergebnis . . . . .	49
3.12	Funktionsweise des Predicted k-Nearest Neighbors-Algorithmus' . . . . .	51
3.13	Schritte des Kalman-Filters . . . . .	52
3.14	Funktionsweise des Kalman-Filters . . . . .	53
3.15	Abfolge der Verfeinerung des Partikel-Filters . . . . .	55
3.16	Ergebnisse unterschiedlicher Clusteringverfahren . . . . .	58
3.17	Funktionsweise K-Means- und EM-Clustering . . . . .	59
4.1	Komponenten von IndoorGPS . . . . .	62
4.2	Reduktion der Messungen bei Ausbleiben von Schritten . . . . .	65

4.3	Auswahl der Lokalisierungsverfahren . . . . .	68
4.4	Eingebundener Grundriss in IndoorGPS . . . . .	69
4.5	Abzuschreitende Pfade und hierauf verteilte Messungen . . . . .	70
4.6	Lokalisierung und Zusatzinformationen . . . . .	70
4.7	11. Obergeschoss der HAW Hamburg . . . . .	73
4.8	ARTTRACK und das für die Ortung zu tragende Optical Target Set . . . . .	74
4.9	Ubisense RTLS . . . . .	74
4.10	Aufbau der Creative Space Testfläche . . . . .	75
4.11	Versuchsaufbau im Creative Space . . . . .	76
4.12	Versuchsaufbau im Living Place . . . . .	77
4.13	Renderbild des Living Place Hamburg . . . . .	78



# 1 Einleitung

Smartphones werden mit steigender Tendenz gegenwärtig von rund drei Vierteln der Einwohner Deutschlands genutzt<sup>1</sup>. Die persönlichen Geräte, die potenziell in der Lage sind, jederzeit aktuelle Informationen im bestmöglichen Kontext anzuzeigen, können damit als allgegenwärtig angesehen werden.

Dank der weltweiten Positionierung durch Technologien wie GPS sind stets aktuelle und zur Nutzungsumgebung passende Informationen alltäglich geworden. Befindet sich der Nutzer auf dem Weg zur Arbeit, können ihm Informationen zum Verkehrsaufkommen angezeigt, alternative Routen angeboten oder die Möglichkeit aufgezeigt werden, die Route einer Person des Vertrauens mitzuteilen. Im Urlaub können hingegen automatisch Übersetzer, Währungsumrechner, das Wetter am Urlaubs- und Heimatort sowie Erkundungstipps zur Verfügung gestellt werden.

Das Bild ändert sich, sobald sich der Nutzer in einem Gebäude befindet. Im Schnitt verbringen Menschen mittlerweile, je nach Quelle, zwischen 80 (vgl. [LCJ<sup>+</sup>15, S. 1]) und 90% (vgl. [PZZ<sup>+</sup>16, S. 1]) ihrer Lebenszeit in Innenräumen. Der GPS-Empfang kann hier in der Regel nicht aufrecht erhalten werden und die Positionierung wird deutlich erschwert. Dabei lassen sich viele Beispiele finden, die eine kontextabhängige Informationsversorgung in Innenräumen sinnvoll erscheinen lassen: Im Flughafen kann der kürzeste Weg zum Gate darüber entscheiden, ob der Flug noch rechtzeitig erreicht werden kann. Im Einkaufszentrum könnte die genaue Ortung das Einkaufen sowohl für den Kunden - dank potenziell kürzerer Laufwege durch automatisch erstellte Routen - als auch für den Geschäftsinhaber - dank genauerer Daten über das Kundenverhalten - erleichtern. Im Museum ließen sich virtuelle Führungen erstellen, die auf den Kunden zugeschnittene Informationen zum aktuell betrachteten Werk enthalten und ihm automatisch im eigenen Tempo die Erkundung ermöglichen.

---

<sup>1</sup><https://www.bitkom.org/Presse/Anhaenge-an-PIs/2016/Bitkom-Pressekonferenz-Smartphone-Markt-Konjunktur-und-Trends-16-02-2016-Praesentation-final.pdf>, Abruf: 15.01.2017

Seit einigen Jahren lassen sich Produkte finden, die sich dieser Problematik annehmen, wie etwa die in einigen Ländern verfügbaren Indoor-Karten innerhalb von Google Maps<sup>2</sup> oder die Produkte von Skyhook<sup>3</sup> und Navizon<sup>4</sup>. Häufig sind die Genauigkeiten der verfügbaren Lösungen allerdings verbesserungswürdig, können nur von Unternehmen eingerichtet werden oder nutzen nur einzelne Sensoren, was einer zuverlässigen Ortung entgegensteht.

Besonders das eigene Zuhause zeigt auf, wie wichtig genaue Ortung in Innenräumen sein kann. Eine Genauigkeit von einigen Dutzend Metern reicht zwar für eine Standortbestimmung aus, die ermöglicht, das Wetter einer entsprechenden Stadt anzuzeigen oder sich grob an einem Ort orientieren zu können; in Innenräumen und speziell im eigenen Zuhause ist eine solche Positionierung allerdings nahezu nutzlos, da der Unterschied zwischen der eigenen und der Nachbarwohnung nicht erkennbar ist, geschweige denn ein Zimmer von einem anderen unterschieden werden kann.

Es fehlt also an einer Lösung, deren Anwendung einfach durchzuführen und deren Genauigkeit ausreichend hoch ist, um den Nutzer innerhalb eines Raums (im Folgenden „raumweite Genauigkeit“) positionieren zu können. Wie im vorhergehenden Hauptseminar [Bar16a] bereits erläutert, existieren hierfür bereits einige Systeme, die eine ausreichende Genauigkeit bieten. Eine Auswahl dieser Systeme sind unter anderem die am Campus der HAW Hamburg installierten Systeme UbiSense RTLS sowie ARTTRACK, die in Kapitel 4.4.2 näher beschrieben werden. Externe Systeme sind in der Regel jedoch für Privatpersonen unerschwinglich und auf einen begrenzten Raum ausgelegt, in dem sie darüber hinaus erst installiert und eingerichtet werden müssen, was den Einsatz für Konsumenten daher nicht sinnvoll erscheinen lässt. Während die Positionierung in Außenarealen unter anderem dank GPS als gelöst gesehen werden kann, lässt sie sich in Gebäuden also nur schwer erreichen (vgl. [ETZ05]).

Ziel dieser Arbeit ist daher, verschiedene Verfahren zur Ortung in Gebäuden zu evaluieren, die ohne kostspieliges Equipment genutzt werden können und eine raumweite Genauigkeit ermöglichen. Da hierzu auf Smartphones zurückgegriffen werden kann, wird im Rahmen der Master-Thesis eine für diesen Zweck entwickelte Android App vorgestellt, für die eine Auswahl der Verfahren implementiert wurde, welche mithilfe der App, soweit sinnvoll, miteinander verglichen werden können.

---

<sup>2</sup><https://www.google.com/maps/about/partners/indoormaps>, Abruf: 18.11.2016

<sup>3</sup><http://www.skyhookwireless.com>, Abruf: 18.11.2016

<sup>4</sup><https://www.navizon.com>, Abruf: 18.11.2016

## Smart Environments und Zielsetzung

Die ausgearbeitete Lösung zur Indoor-Ortung soll durch die Bestimmung des Nutzerstandorts die Möglichkeit der Kontexterkenkung sicherstellen. Der Einsatzort tritt hierfür in den Hintergrund und kann unterschiedlichste Formen annehmen. Denkbar wäre der Einsatz in der Automatisierung, bei der Robotern ermöglicht wird, in ihrer Umgebung von sich aus Aufgaben wie das Lagern und Auffinden von Paketen zu erledigen. Auch die Automatisierung des Alltags stellt einen möglichen Einsatzzweck dar, womit das Ubiquitous Computing unterstützt würde.

Als Ubiquitous Computing (kurz „UbiComp“) wird die Allgegenwärtigkeit von rechnergestützten Diensten bezeichnet, die den Nutzer automatisch und unmerklich in seinen Tätigkeiten unterstützen. Der Begriff wurde Anfang der 90er Jahre von Mark Weiser geprägt und als die Rechnerallgegenwärtigkeit durch das Verschwinden von Technologie aus der Wahrnehmung der Nutzer beschrieben (vgl. [Wei91]). Hierfür bietet es sich an, dass der Kontext des Nutzers bestmöglich verstanden wird. Der Gebrauch von UbiComp kann damit beispielsweise im privaten wie auch öffentlichen Raum geschehen.

Im öffentlichen Raum sind Gebäude wie Museen, Einkaufszentren oder Flughäfen denkbar, die dem Nutzer ohne beziehungsweise mit geringem Aufwand einen Zusatznutzen bieten können. Während bei Museen dabei das Bereitstellen von Informationen verknüpft mit dem Ort eine große Rolle spielt, dreht sich in Einkaufszentren vieles um das auf den Kunden zugeschnittene Angebot von Waren und Dienstleistungen, indem dieser zum Geschäft seiner Wahl geleitet und bei seinem Kauf unterstützt werden kann. Gebäude wie Bahnhof oder Flughafen bieten sich hingegen besonders für die Wegberechnung zum Bahnsteig oder Terminal an, sodass der Reisende möglichst viel Zeit bei der Suche sparen kann.

Im privaten Raum hingegen ist es relevant, den Alltag des Nutzers optimal einschätzen und unterstützen zu können. Hierbei spricht man vom vernetzten Wohnen, beziehungsweise Smart Home, welchem durch den Kontext erlaubt wird, automatisch auf den Bewohner reagieren zu können und damit keiner oder nur geringer Steuerung bedarf.

Wovon die Rede ist, wenn vom Kontext gesprochen wird, zeigt Dourish in seiner Arbeit (vgl. [Dou04]). Er befasste sich mit dem Begriff als Basis des UbiComp unter dem technischen und sozialen Gesichtspunkt. Der Kontext wird dabei als Rahmen dargestellt, innerhalb dessen Aktivitäten stattfinden. Wie bereits im Hauptseminar erörtert (vgl. [Bar16a]), bedeutet dies im

Zusammenhang mit Smart Homes etwa, dass sich die Aktivitäten „einen Raum betreten“, „auf dem Sofa Platz nehmen“ und „den Fernseher anschalten“ allesamt innerhalb des Kontextes „Fernsehen“ abspielen. Die Position wird zudem als ein integraler Bestandteil herausgestellt, womit der Bogen zu dieser Arbeit gespannt wird.



Abbildung 1.1: Vereinfachte Darstellung eines Smart Homes<sup>5</sup>

Das Smart Home könnte durch einen korrekt erkannten Kontext von der Beleuchtung und der Musikuntermalung im Aufenthaltsraum des Nutzers über die Sicherheit und Zutrittskontrolle bis hin zur Überwachung von Strom, Wasser und Entsorgung alle Aspekte des Haushalts übernehmen (siehe Abbildung 1.1). Es wäre somit denkbar, dass ein smartes Türschloss automatisch zu- und entsperrt, die Beleuchtung sowie Musik dem Bewohner folgt oder die Heizung nur jene Räume heizt, in denen sich Menschen aufhalten. Auch die Informationsversorgung des Bewohners könnte als standortbasierter Dienst umgesetzt werden, sodass ihm etwa Rezepte angezeigt werden, wenn seine Tätigkeit als Kochen erkannt wird. Als Voraussetzung für ein effizientes Smart Home kann also die Erkennung des Kontexts angesehen werden. Diese soll durch die in der vorliegenden Arbeit behandelte Positionsermittlung unterstützt werden, wobei eine Genauigkeit von wenigen Metern (im Folgenden „raumweite Genauigkeit“) angestrebt

<sup>5</sup><http://gstylemag.com/2015/01/19/building-a-smart-home-series-step-two-plan-your-home-bash>, Abruf: 21.10.16

wird.

Besonders für den industriefernen Einsatz, speziell dem Smart Home, ist eine Lösung nachteilig, die hohen technischen und finanziellen Aufwand benötigt. Aus diesem Grund wurde ein „IndoorGPS“ genanntes System erarbeitet, das in praktisch jeder Umgebung einsetzbar ist und die Ortung mit in dieser Arbeit erarbeiteten Verfahren demonstrieren soll. Für die Umsetzung eines solchen universal einsetzbaren Systems wird von Faragher et al. das konsequente Zurückgreifen auf vorhandene Ressourcen als Notwendigkeit angesehen (vgl. [FSN12]). Aus diesem Grund wird neben der Smartphone-Plattform auf die Nutzung bereits vorhandener Signale gesetzt.

Um die Umsetzbarkeit von Smart Homes und Ubiquitous Computing sowie ihre Auswirkungen auf den Alltag der Nutzer erforschen zu können, wurde am Campus der HAW Hamburg das Living Place aufgebaut (vgl. [EKV<sup>+</sup>11]). Beim Living Place handelt es sich um eine 140 m<sup>2</sup> große, voll funktionsfähige und vernetzte Wohnung, die als Labor zur Erforschung des zukünftigen Wohnens genutzt wird. Im Living Place sind Computer und Sensoren in die den Nutzer umgebenden Objekte integriert, um eine allgegenwärtige Unterstützung durch positionsbasierte Dienste zu ermöglichen. Hierzu zählen Kamera-, Ortungs- sowie Schlafanalysesysteme, Mikrofone, steuerbare Beleuchtung und mehr.

Dank der ausgiebigen Sensorik liegt es nahe, das Living Place als Versuchsort für einen Praxistest des in dieser Arbeit entwickelten Ortungssystems zu nutzen. Dies ist im Experiment geschehen, dessen Ergebnisse im Kapitel 4.4.5 besprochen werden. Eine detaillierte Vorstellung von IndoorGPS erfolgt hingegen in Kapitel 4.

Neben dem Living Place wurde an der HAW Hamburg noch das interdisziplinär ausgelegte Creative Space<sup>6</sup> errichtet, um Hypothesen neuer Technologien evaluieren und, beispielsweise durch Prototypen, kurzfristig validieren zu können. Im Creative Space werden Themen wie Virtual Reality und kollaboratives Arbeiten sowie Indoor Positionierung mittels optischer und funkbasierter Systeme (detaillierter beschrieben in Kapitel 4.4.2) behandelt und erprobt. Neben dem Living Place findet eine Untersuchung der Innenraumlokalisierung mit Smartphones innerhalb dieser Umgebung statt. Erläutert wird dieser Versuch im Kapitel 4.4.4.

---

<sup>6</sup><http://csti.haw-hamburg.de>, Abruf: 15.01.2017

Die vorliegende Arbeit ist folgendermaßen aufgebaut: Die verfügbare Sensorik eines Smartphones sowie ihre Arbeitsweise und Sinnhaftigkeit für die Positionsermittlung wird in Kapitel 2 vorgestellt. Darauf aufbauend werden in Kapitel 3 Verfahren zur Positionierung beschrieben, um ein Verständnis für die zur Verfügung stehenden Möglichkeiten, ihre Genauigkeit und Umsetzbarkeit zu schaffen. Darüber hinaus wird erläutert, welche Verfahren für die Umsetzung in IndoorGPS infrage kommen.

In Kapitel 4 erfolgt die Vorstellung des IndoorGPS-Systems selbst, seiner Architektur sowie Besonderheiten wie den Optimierungsmodulen und schließlich die Messung des Systems unter verschiedenen Gesichtspunkten und in unterschiedlicher Umgebung. Abgeschlossen wird die Arbeit letztlich mit dem **Fazit und Ausblick**, womit der Grundstein für eine potenziell nachfolgende Arbeit gelegt wird.

## 2 Sensorik eines Smartphones

Moderne Smartphones stellen durch ihren hohen Verbreitungsgrad und die umfangreiche verbaute Sensorik eine besonders vielversprechende Möglichkeit für ein skalierendes System zur Indoorpositionierung dar. Sie bergen allerdings ebenso, im Vergleich zu fest installierten Systemen, aufgrund ihrer Portabilität teils große Einschränkungen bei der Genauigkeit. Die Möglichkeiten zur Ortung herauszuarbeiten sowie besagte Einschränkungen aufzuzeigen, ist Inhalt dieses Kapitels.



Abbildung 2.1: Im Smartphone verbaute Sensoren [Eigene Darstellung auf Basis von Handskit<sup>1</sup>]

Eine Vielzahl der im Smartphone verbauten Sensoren lassen sich für die Ortung in Innenräumen nutzen. Vom Gebrauch von Funkwellen mittels Bluetooth und WiFi über das Erkennen von Identifikationsmerkmalen der Umgebung mittels Kamera bis zur Ortung durch Schall oder der Unterscheidung von Etagen mit einem Barometer existieren hierzu etliche Wege. Abbildung

<sup>1</sup><https://facebook.github.io/design/handskit.html>, Abruf: 23.11.16

2 zeigt eine Übersicht über die Sensoren, die in vielen kommerziell erhältlichen Mobiltelefone enthalten sind und jeweils in den entsprechenden Unterkapiteln behandelt werden.

## 2.1 GPS, Mobilfunk und FM

Die Ortung durch GPS hat mit ihrem Einzug in Navigationsgeräte und Mobiltelefone die mobile Navigation revolutioniert. Die Genauigkeit von wenigen Metern unter freiem Himmel (vgl. [RKT<sup>+</sup>15]) trug einen erheblichen Teil zu einer mittlerweile allgegenwärtigen Navigation und dem Etablieren von Kartendiensten auf Mobilgeräten bei.

Für die Indoor-Positionierung sind sowohl GPS als auch die Ortung via Mobilfunk hingegen kaum geeignet. Wie in Abbildung 2.2 dargestellt, wird durch die Wände und Decken eines Gebäudes die zum Betrieb benötigte freie Sicht zwischen GPS-Satellit und Empfänger verhindert, womit kein Verbindungsaufbau stattfinden kann.




Abbildung 2.2: Empfang von GPS- und Mobilfunksignalen innerhalb von Gebäuden<sup>2</sup>

Mobilfunksignale können zwar, wie auf der rechten Seite der Grafik ersichtlich, durch die meisten Wände dringen, sodass das Telefonieren in Gebäuden häufig weiterhin möglich ist. Problematisch ist dabei jedoch die Signalabschwächung, weshalb die Abstände zu den Sendemasten nicht korrekt berechnet werden können und eine Triangulation nicht zuverlässig zur

<sup>2</sup><http://obamapacman.com/2011/07/apple-iphone-tv-signal-location-positioning-gps-patent>, Abruf: 07.11.16



Ortung genutzt werden kann. Näheres zum Vorgehen der Triangulation im Kapitel 3.1.1.

Machaj et al. (vgl. [MBB14]) befassten sich in ihrer Arbeit mit der Innenraum-Lokalisierung durch GSM-Signale. Sie ermittelten hierbei einen geringeren Unterschied zwischen den zur Ortung notwendigen, empfangenen Signalstärken im Vergleich zu WiFi, da Mobilfunkstationen im Schnitt deutlich weiter entfernt sind und deshalb die Signale auf einem niedrigeren Frequenzband senden. Hieraus folgte zwar auf der einen Seite eine robustere Lokalisierung, welche sich als vergleichsweise störunanfällig herausstellte; auf der anderen Seite liegt die Positionierungsgenauigkeit deutlich unter der von auf WiFi-basierenden Systemen. Besonders dank ihrer geringen Störanfälligkeit werden Mobilfunksignale aber trotz der relativ niedrigen Genauigkeit in abgeschwächtem Maße in IndoorGPS unterstützend zur Ortung hinzugezogen.

An der Beijing University of Posts and Telecommunications wurde 2012 ein vergleichsweise genaues System zur Indoor Positionierung über Mobilfunk-Signale entwickelt. Das Time & Code Division-Orthogonal Frequency Division Multiplexing genannte Verfahren ermöglicht Genauigkeiten von unter drei Metern sowohl in Außen- als auch in Innenräumen (vgl. [DYY<sup>+</sup>13, S. 48]) und ist durch seine, dem Mobilfunk entsprechende, hohe Reichweite relativ kosteneffizient bereitstellbar. Für eine globale Nutzung ist allerdings die flächendeckende Integration in Sendemasten vonnöten, was einer Markteinführung in naher Zukunft im Weg steht.

Tian et al. (vgl. [TDA<sup>+</sup>15]) entwickelten ein auf GSM-Signalen basierendes System mit raumweiter Genauigkeit. Durch das Verbinden und anschließende Filtern der Signale mehrerer Mobilfunkanbieter wurde eine raumweite Genauigkeit in 98% des Versuchs erreicht. Eine ähnlich hohe Quote lässt sich mit Smartphones zwar nicht erreichen, da es sich nur mit dem Netz eines Anbieters verbindet und damit deutlich weniger Informationen verwerten kann, es unterstreicht aber die grundsätzliche Nutzung des Signals in IndoorGPS mit theoretisch guten Ergebnissen.

Das Orten mittels FM-Radio schließlich wurde in der Arbeit von Chen et al. (vgl. [CLLP12]) behandelt. Gegenüber WiFi fiel die Erkennung dabei sowohl genauer als auch weniger fehleranfällig aus, blieb über den Zeitverlauf konstanter und ermöglichte eine raumweite Positionierung. Abgesehen davon wurde demonstriert, dass FM-Signale unabhängig von WiFi-Signalen sind und sich daher gut ergänzend nutzen lassen. Trotz der guten Ergebnisse werden FM-Signale in IndoorGPS nicht genutzt, da sie weder in iOS noch in Android standardmäßig ansprechbar sind. Sollte sich dieser Zustand herstellerseitig ändern, steht mit dem FM-Radio ein vielver-

sprechender Sensor für eine potenzielle Weiterentwicklung der Software zur Verfügung.

### 2.2 WiFi und Bluetooth

Unter anderem dank seiner hohen Verbreitung ist WiFi eine häufig genutzte Basis zur Ortung mobiler Geräte. Die Hardwareinstallation ist damit im Normalfall bereits erfolgt und erfordert keine zusätzliche Investition mehr. Durch die Überlagerung vieler Signale aus der Umgebung (in Wohngebieten etwa die der Nachbarwohnungen, in Bürokomplexen die der umliegenden Büros und so weiter) muss zudem vom Lokalisierenden keine besondere Rücksicht auf die Reichweite der Abdeckung gelegt werden. Allerdings hat WiFi seine Ursprünge nicht in der Positionierung, weshalb eine genaue Ortung nicht immer einfach zu erreichen ist und in der Regel vergleichsweise viele Zugangspunkte mit starkem Signal erfordert.

Bereits im Hauptprojekt [Bar16b] wurde erörtert, dass die mit WiFi-Ortung erreichbaren Genauigkeiten grundsätzlich bei etwa einem Meter liegen, was von Yang et al. (vgl. [YS15]), und durch die Kombination mit Beschleunigungssensoren von Chen et al. (vgl. [CZJ<sup>+</sup>15]) demonstriert werden konnte. Die Abweichung bei der Ortung konnte in Projekten wie SpotFi (vgl. [KJBK15]) und Chronos (vgl. [VKK16]) noch unterschritten werden. SpotFi nutzt hierzu etwa die Signaleintrittswinkel für eine mit circa einem halben Meter besonders genaue Positionierung, benötigt allerdings sowohl spezielle WiFi-Chips als auch einen zentralen Server, um die anfallenden Berechnungen durchführen zu können.

Mit Chronos wird hingegen eine nochmals genauere Positionierungsleistung erreicht, die mit nur einem Access Point und ohne vorherige Begehung der Umgebung auskommt. Besonders für kleinere Unternehmen und das Smart Home wäre eine solche Lösung deshalb interessant, da hier ein Gerät meist schon vorhanden ist und sich der Installationsaufwand damit stark in Grenzen hält. Die Genauigkeit von wenigen Dezimetern, die durch eine besonders akkurate Erkennung von Laufzeitunterschieden durch schnelle Frequenzwechsel auf Seiten des Routers erreicht wird, setzt allerdings eine angepasste Routerfirmware und einen neu entwickelten Kernel am Gerät voraus. Dies erschwert die Nutzung in Systemen wie IndoorGPS aktuell stark, da angepasste Geräte nicht als gegeben vorausgesetzt werden können, auch wenn sich dieser Zustand in Zukunft noch ändern könnte.

Ma et al. (vgl. [MGHX15]) nutzten die empfangenen WLAN-Signale, um das Ausstrahlverhalten des Senders zu charakterisieren. Das Vorgehen der Charakterisierung, probabilistisches Verfahren genannt, wird dabei in Kapitel 3.1.2 näher beschrieben. Anschließend wurden die wahrscheinlichsten Messpunkte mittels gewichtetem k-Nearest Neighbors (s. hierzu Kapitel 3.5.1) verrechnet, was zu einer minimalen Abweichung von etwa eineinhalb Metern führte. Allerdings merkten die Autoren an, dass es sich bei der Dauer der für die Einmessung und Charakterisierung benötigten Zeit um ein für den Großteil der Anwender wichtiges Problem handelt und bereits die Filterung der Position durch k-Nearest Neighbors eine deutliche Verbesserung der Positionierungsleistung aufweist. Aus diesem Grund wird auf ein probabilistisches Verfahren in IndoorGPS vorerst verzichtet, eine Filterung durch k-Nearest Neighbors allerdings implementiert.

Neben der Ortung per WiFi lassen sich Nutzer auch per Bluetooth orten, vereinfacht dargestellt in Grafik 2.3 (hier in Kombination beider Signalarten).

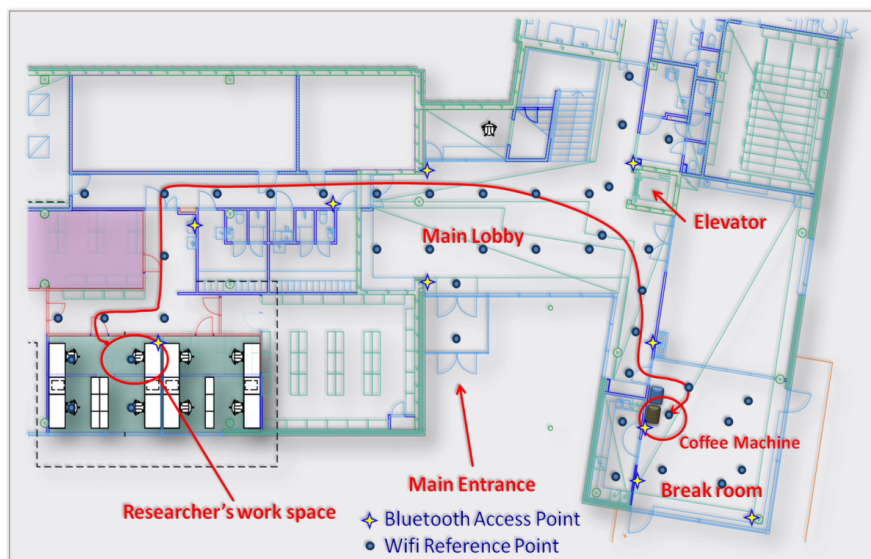


Abbildung 2.3: Ortung im Bürokomplex mit WiFi und Bluetooth<sup>3</sup>

Dabei liegt die erreichbare Genauigkeit von Bluetooth je nach Dichte der vor Ort verteilten Bluetooth-Sender bei niedrigerem Energieverbrauch teils deutlich über der des WiFi, wie etwa Zhao et al. (vgl. [ZXM<sup>+</sup>14]) bestätigten. Faragher und Harle (vgl. [FH14]) stellten darüber hinaus fest, dass sich die Genauigkeit mit bis zu acht Sendern stetig verbessert. Kriz et al. (vgl.

<sup>3</sup><http://www.fgi.fi/fgi/themes/indoor-navigation>, Abruf: 07.11.16

[KMK16]) reduzierten hingegen die Abweichung ihres Systems, indem sie die Positionierung via WiFi und Bluetooth kombinierten, was ebenfalls zu einer deutlichen Steigerung der Genauigkeit führte. Grundsätzlich problematisch an der Ortung via Bluetooth ist allerdings, dass die Senderverbreitung nicht als allgegenwärtig gesehen werden kann, wie es aktuell beim WiFi der Fall ist. Optimal wäre also eine Positionierungslösung, die vorhandene Bluetooth-Sender zur Verbesserung der Positionierung nutzt, bei fehlenden Sendern jedoch nicht in der Leistung abfällt. Bluetooth wird deshalb in IndoorGPS als optionale Signalquelle genutzt, die nur bei Vorhandensein zur Ortung verwendet wird.

Die Ausstattung einer Umgebung mit Bluetooth-Sendern, wegen ihres regelmäßigen Aussendens von Signalen „Beacons“ (Leuchtfeuer) genannt, stellt dabei mit geringen Stückkosten eine vergleichsweise günstige Anschaffung dar. Breite Bekanntheit erlangten Beacons erstmals durch Apple, das speziell für die Ortung die Referenz „iBeacon“ vorstellte<sup>4</sup>.

Darüber hinaus ist ein hervorhebenswerter Vorteil der Beacons die mögliche Kommunikation mit dem Nutzer, beziehungsweise im geschäftlichen Umfeld mit einem potenziellen Kunden. Hier sind Beispiele wie die Unterstützung des Kunden beim Einkauf, die Anzeige von passenden Informationen in einer Ausstellung oder das Vorstellen der Speisekarte auf dem Smartphone in einem Restaurant denkbar. Der Betreiber eines solchen Betriebs erhält damit leicht über die reine Ortung hinausgehende Funktionen. Diese Möglichkeit trieb Google mit dem Protokoll Eddystone<sup>5</sup> voran, das der Verknüpfung von digitaler und analoger Welt durch vom Empfangsgerät zu öffnende Anhänge dient.

Ein Beispiel einer typischen Kundenbeziehung lässt sich der Bilderserie 2.4 entnehmen: Der Kunde wird beim Betreten des Geschäfts auf die digitalen Services hingewiesen und nach dem Akzeptieren der Interaktion zum Produkt seines Interesses geleitet. Der Geschäftsinhaber erhält nun die Möglichkeit, dem Kunden auf einem Display persönliche Anzeigen zu schalten. Ist der Kunde interessiert, braucht er seine Einkäufe nicht selbst zu tragen, sondern legt sie in den digitalen Warenkorb und lässt sie sich vom Unternehmen nach Hause liefern. Beispiele wie diese zeigen erneut, wie ortsabhängige Dienste - besonders durch Bluetooth - die Erfahrung für den Nutzer verbessern können.

---

<sup>4</sup><https://developer.apple.com/ibeacon>, Abruf: 23.11.2016

<sup>5</sup><https://developers.google.com/beacons>, Abruf: 23.11.2016

<sup>6</sup><http://estimote.com>, Abruf: 13.10.16

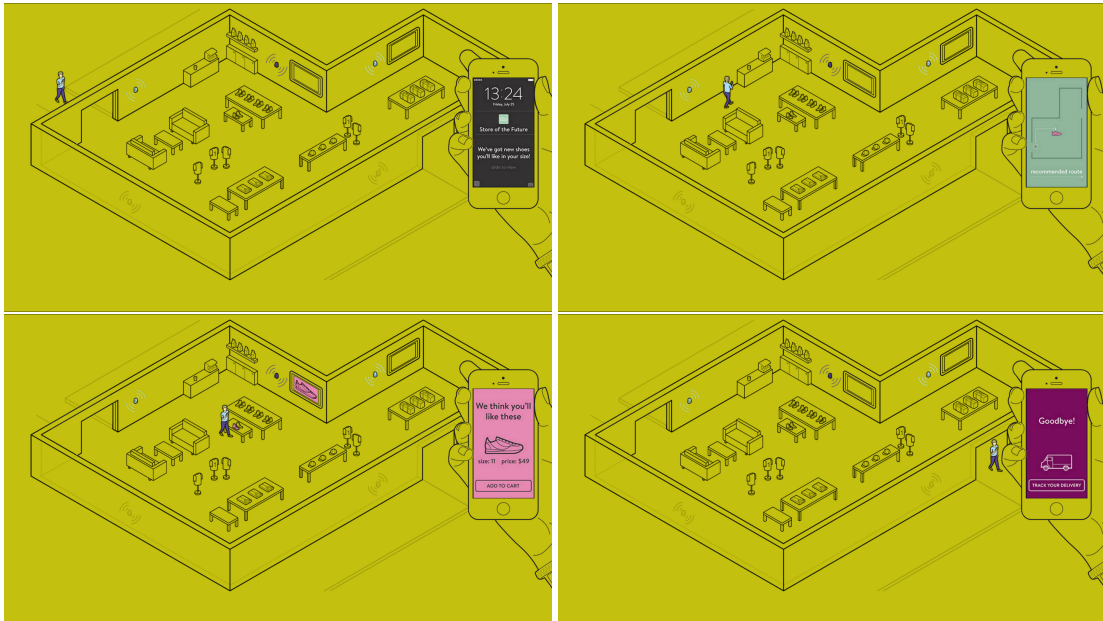


Abbildung 2.4: Abfolge einer Kundenkommunikation per Bluetooth-Beacon<sup>6</sup>

Geeignet für die Ortung mit raumweiter Genauigkeit können folgend sowohl WiFi- als auch Bluetooth-Sensoren gesehen werden, wie in mehreren Arbeiten sowohl im Experiment unter Laborbedingungen (vgl. [SZLV14]) als auch im realen Einsatz demonstriert wurde (vgl. [HJLY14]). WiFi benötigt durch seine hohe Verbreitung dabei in der Regel keine weitere Hardware, bei Bluetooth hingegen ist die bessere Positionierungsleistung sowie die direkte Kommunikation mit dem Nutzer von Vorteil. Aus diesen Gründen werden beide Signalarten in IndoorGPS eingesetzt.

### 2.3 Magnetfelder

Werden Magnetfelder als Lokationsgrundlage in Innenräumen genutzt, gilt es, die Strukturen und Anomalien des Erdmagnetfelds zu erkennen und diese als Signatures zu nutzen. Im Gegensatz zur Störung von Funkwellen etwa durch Stahl- und Betonanteile in Gebäudewänden, erhöhen Störungen der Magnetfelder ebensolche Signatures und damit den Wiedererkennungswert der auf ihnen basierenden Positionen. Bild 2.5 stellt das Magnetfeld im Inneren eines Gebäudes stellvertretend als Heatmap dar, wobei rote Bereiche auf stark und blaue auf schwach ausgeprägte Feldstärken hinweisen. Wichtig zur Differenzierung ist hierbei nicht die




Abbildung 2.5: Simulierte Darstellung von Magnetfeldsignaturen<sup>7</sup>

absolute Stärke des Feldes, sondern die Stärke der Abweichungen über die Fläche.

Wie schon im Grundprojekt [Bar15] erwähnt, geht die Forschung in der Orientierung auf Basis des Erdmagnetfeldes auf die 70er Jahre zurück. Wiltschko und Wiltschko (vgl. [WW72]) untersuchten in ihrer Arbeit die Flugrichtung von Vogelschwärmen sowie deren Fähigkeit, magnetische Felder erkennen und sich von ihnen leiten zu lassen. Haverinen und Kempainen (vgl. [HK09]) nutzten diese Erkenntnis, um sowohl einen Roboter als auch eine Person in mehreren ausgewählten Gebäuden und über längere Zeitverläufe hinweg zuverlässig orten zu können, woraus im Anschluss das Unternehmen IndoorAtlas<sup>8</sup> entstand.

Die Funktionsweise einer Magnetfeldortung ähnelt stark der funkwellenbasierter Verfahren. Grundsätzlich wird der Kompass eines Geräts genutzt, um die Feldstärken in Richtung der drei Achsen X, Y und Z zu ermitteln und aus diesen eine Gesamtintensität, vergleichbar mit der Signalstärke eines Funksignals, zu berechnen. Der Arbeit von Putta et al. (vgl. [PMK15]) lässt sich entnehmen, dass gegenüber dem simplen Addieren der Intensitätsbeträge das Bilden des Summenvektors der drei als Vektoren angenommenen Feldstärken die genauere Variante darstellt. Da hierbei die Orientierung des Geräts ausgeglichen wird, stellt dies auch das zu

---

<sup>7</sup><http://www.gizmodo.com.au/2014/05/this-company-uses-earths-magnetic-field-to-see-inside-buildings>, Abruf: 23.11.16

<sup>8</sup><https://www.indooratlas.com/about>, Abruf: 23.11.16

erwartende Ergebnis und die in IndoorGPS genutzte Implementierung dar.

Vorteilhaft an Magnetfeldern ist neben der Infrastrukturunabhängigkeit (das Erdmagnetfeld ist an jedem Ort der Erde immer verfügbar) die Stabilität über die Zeit. Diese bleibt auch bei sich ändernder Umgebung erhalten, etwa beim Umräumen von Möbeln oder ähnlichem (vgl. [HK09]). Auch die Überlagerung mit Funksignalen ist prinzipbedingt nicht möglich, weshalb sich beide Ortungsarten als ideale Ergänzung zueinander herausstellen.

Mit ihrem System *Magicol* erreichten Shu et al. (vgl. [SBS<sup>+</sup>15]) mit einer Kombination aus Magnetfeldern, WiFi und dem Accelerometer (Näheres zu diesem Sensor in Kapitel 2.4) eine Genauigkeit im Bereich weniger Meter. Durch die Kombination mit den zusätzlichen Sensoren erhielten die Autoren gegenüber dem alleinigen Nutzen des Magnetometers zum einen stabilere sowie genauere Ergebnisse, da Magnetfelder für sich genommen aufgrund ihrer geringen Unterscheidbarkeit nicht für die zuverlässige Ortung ausreichen. Zum anderen behielt das System seine Robustheit gegenüber Umweltveränderungen und der Datenaufnahme mit unterschiedlichen Geräten. Erkennbar in den Grafiken 2.6 (Umweltfaktoren) und 2.7 (Messung mit unterschiedlichen Geräten).

Problematisch am *Magicol*-Ansatz ist jedoch der zeitaufwändige und komplexe Einmessvorgang, da die Magnetfeldstrukturen erst im Zeitverlauf durch das Umherschreiten der Nutzer aufgebaut und in über die Fläche verteilten Vektoren abgelegt werden. Anschließend werden die Ergebnisse der WiFi-Messungen mit den Magnetfeldern fusioniert (siehe Kapitel 3.4) und mit einem hierfür angepassten Partikel-Filter (siehe Kapitel 3.5.3) gefiltert. Bei der Fusion konnten die Autoren beobachten, dass sich die WiFi-Signale und Magnetfeldsignaturen als zueinander komplementär herausstellten. Diese Erkenntnis wird in IndoorGPS genutzt, indem beide Sensorarten ebenfalls, allerdings auf einem simpleren Ansatz basierend, miteinander verbunden werden.

Sollte sich die Erkennung mittels Magnetfeldsignaturen als zu ungenau herausstellen, kann die Stabilität des Feldes noch durch die Orientierung des Gyroskops erweitert werden, wie von Li et al. (vgl. [LZL<sup>+</sup>16]) gezeigt. Durch die Berücksichtigung des Neigungswinkels erweiterten sie das Magnet-Modell um zwei weitere Dimensionen (die horizontale, respektive vertikale Drehung) und erreichten damit sowohl eine höhere Unabhängigkeit von der Orientierung des Geräts als auch von Arealen mit geringer WiFi-Abdeckung und indifferenten Magnetfeldern. Eine vereinfachte Annäherung an diese Herangehensweise ist in IndoorGPS eingeflossen und




Abbildung 2.6: Einfluss von Umweltfaktoren auf das gemessene Magnetfeld 1 [SBS<sup>+</sup>15]

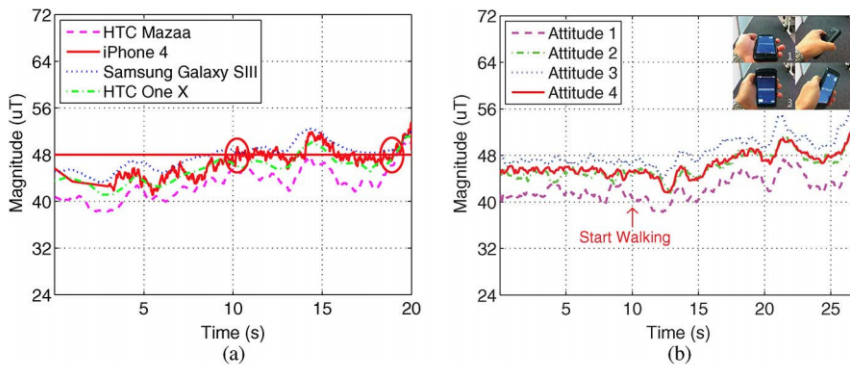


Abbildung 2.7: Einfluss der Messung mit unterschiedlichen Geräten auf das gemessene Magnetfeld 2 [ebd.]

wird in Kapitel 3.1.2 beschrieben.

Mit MaLoc schließlich entwickelten Xie et al. (vgl. [XGT<sup>+</sup>14]) ein vergleichsweise komplexes System und verbesserten die Erkennung magnetfeldbasierter Systeme durch ein Partikel-Filter (siehe hierzu Kapitel 3.5.3), dynamische Schrittlängenschätzung und der hybriden Messung von Magnetfeldsumme und Vektorlänge auf jeweils unterschiedlicher Höhe. Hiermit wurde zwar eine höhere Unabhängigkeit vom verbauten Sensor und der Haltung des Smartphones gegenüber der einfachen Messung erreicht; allerdings sprechen die Autoren dem Messverfahren besonders in Anbetracht des höheren Messaufwands nur wenig Aussagekraft zu. Das von Xie et al. für die Lokalisierung optimierte Partikel-Filter zieht zudem trotz der hohen Genauigkeit zwischen etwa einem und drei Metern einen relativ hohen Rechenaufwand nach sich und ist somit für IndoorGPS aktuell nicht interessant.



## 2.4 Beschleunigung und Orientierung

Das Accelerometer nimmt unter den Sensoren eine Sonderrolle ein, da es nicht auf Signale jeglicher Art angewiesen ist, gleichzeitig aber auch keine absolute Positionierung, sondern nur das Berechnen einer relativen Abweichung ermöglicht. Wird es zusammen mit dem Gyroskop genutzt, um von der Beschleunigung in eine Richtung auf die Position schließen zu können, spricht man von der aus der Seefahrt stammenden Koppelnavigation. Tiefergehende Informationen über die Funktionsweise der relativen Positionierung und Besonderheiten wie der akkumulierende Fehler und die Driftkorrektur werden in Kapitel 3.2 gegeben.

Dank der Signalunabhängigkeit lässt sich die Koppelnavigation selbst im Flugmodus am Smartphone nicht deaktivieren. Die Ortung kann daher in gewissem Rahmen immer gewährleistet werden, weshalb sich das Accelerometer optimal als Unterstützung für Positionierungssysteme beim Ausbleiben von Signalen eignet.

Auf Beschleunigungssensoren basierende Systeme können laut Harle (vgl. [Har13]) unterschieden werden in solche, die Accelerometer und Gyroskop nutzen, um kontinuierlich die Bewegung in eine Richtung zu messen, und solche, die mithilfe des Schrittzählers auf die Schritte in die entsprechende Richtung konzentrieren. Das Magnetometer zur Orientierung zu nutzen eignet sich hingegen kaum aufgrund der teilweise sehr starken Magnetfeldverzerrungen in Gebäuden. In Abbildung 2.8 werden beide Arten der Ortung gezeigt, oberhalb das sehr kleinschrittige Koppelnavigationssystem „Inertial Navigation System“ (INS), unterhalb das schrittzählerbasierte „Step-and-Heading System“ (SHS). Erkennbar ist, dass der tatsächliche Pfad, gekennzeichnet durch die gestrichelte Linie, vom INS sehr akkurat erkannt wird, während das SHS nur einzelne Schritte erkennt und dadurch teilweise recht stark vom Pfad abweicht.

INS sind im Smartphone durch die Platzeinschränkung im Vergleich zu militärischen Sensoren sehr ungenau, darüber hinaus normalerweise nicht kalibriert und von der Orientierung des Gyroskops abhängig. Aus diesen Faktoren folgt sehr schnell ein hohes Abweichen von der korrekten Position, das mit Filtern, wie etwa einem Kalman- (Näheres in Abschnitt 3.5.2), bzw. Partikel-Filter (Abschnitt 3.5.3), reduziert und, zum Beispiel mit weiteren Sensoren, regelmäßig korrigiert werden muss.

Die Lokalisierung durch Schrittzähler im SHS weist eine geringere Genauigkeit gegenüber der kontinuierlichen Ortung auf und stellt sich besonders dann als problematisch heraus, wenn




Abbildung 2.8: Unterteilung von auf Accelerometer basierenden Ortungssystemen [Har13]

nicht geradeaus, sondern stellenweise seitwärts gelaufen oder sogar gehumpelt wird. Besonders bei Menschen mit eingeschränktem Bewegungsapparat, wie Patienten im Krankenhaus, erhöht sich die Fehlerrate um ein Vielfaches. Darüber hinaus muss die Schrittlänge, bestenfalls dynamisch zur Laufzeit, geschätzt werden, was durch die teilweise starke Abhängigkeit der Schrittlänge von der Person erneut zu Ungenauigkeiten führen kann (vgl. [Wei02]). Bei der Positionierung mittels Schrittzähler handelt es sich nach Harle aber um die bei mobilen Geräten einzig praktische Möglichkeit, da die Bewegungen bereits bereinigt und dem menschlichen Bewegungsapparat angepasst sind. So wird etwa beim Heben des Beins keine Bewegung auf der Z-Achse registriert, was bei raupen- oder radbetriebenen Robotern nicht relevant ist.

Während mit militärischem Equipment oder am Fuß getragenen Sensoren durch eine erhöhte Genauigkeit und regelmäßige Driftkorrektur allein mit Koppelnavigation eine gute Positionierungsleistung möglich ist, folgert der Autor, dass mit dem Accelerometer in Smartphones nur schwer eine ausreichende Genauigkeit zu erreichen sei. Darüber hinaus stellen die besonders für den Einsatz in Smartphones wichtigen Filter hohe Anforderungen an die Prozessorleistung und den Energieverbrauch des Geräts. Aus diesen Gründen werden meist hybride Systeme in Verbindung mit anderen Verfahren genutzt (vgl. beispielsweise [FH13], [KKB<sup>+</sup>15], [HZJ<sup>+</sup>14]

und [FSN12]).

Aus Aufwandsgründen wird eine Koppelnavigation vorerst nicht in IndoorGPS implementiert, da es ein sich von der absoluten Ortung durch Signalabgleich vollständig unterscheidendes Verfahren darstellt und mit diesem nicht ohne Weiteres fusionierbar ist (siehe Kapitel 3.4). Da durch die Koppelnavigation allerdings unter anderem gänzlich neue Filterarten und Ortungsverfahren ermöglicht werden, die die Genauigkeit des Systems potenziell stark verbessern können (mehr zu diesen Themen in Kapitel 3), handelt es sich um eines der wichtigsten Themen für eine Weiterentwicklung des Projekts.

Es wird jedoch abseits der Koppelnavigation der Schrittzähler genutzt, um die Erkennung des Systems bei Nichtbewegen zu pausieren und den Energieverbrauch zu reduzieren. Erklärt wird das Vorgehen in Abschnitt 4.2.2.

## 2.5 Optische Ortung

Die optische Ortung lässt sich in die zwei Bereiche „Ortung des Objekts durch vorinstallierte Kameras“ (in diesem Fall der Nutzer, beziehungsweise das Smartphone) und „Orientierung anhand von Signaturen durch eine Kamera am Objekt selbst“ unterteilen.

Erstere Herangehensweise benötigt mit vorinstallierten Kameras zusätzliche Infrastruktur und ist aus diesem Grund für ein skalierendes System wie IndoorGPS nur zu Referenzzwecken geeignet. Ein Beispiel einer solchen Installation stellt das mit Infrarotkameras arbeitende ARTTRACK System<sup>9</sup> dar, dessen Genauigkeit sich im Milimeter-Bereich befindet (vgl. [PK07]). Dank der vergleichsweise hohen Genauigkeit und der Verfügbarkeit im Creative Space auf dem Campus HAW Hamburg, wird es als Referenzsystem zum Überprüfen der maximalen Genauigkeit von IndoorGPS genutzt. Beschrieben wird dieses Vorgehen in Kapitel 4.4.

Das Gegenstück zum Tracken durch externe Kameras bilden Image Based Localization Projekte, welche die eingebaute Kamera nutzen, um Umgebungssignaturen wiederzuerkennen und anhand dieser die eigene Position berechnen. Google Tango<sup>10</sup> ist etwa ein Beispiel für ein solches System. Es nutzt ein Tiefenkamerasystem und die verbauten Beschleunigungssensoren,

---

<sup>9</sup><http://www.ar-tracking.com/products/tracking-systems/arttrack-system>,  
Abruf: 28.10.2016

<sup>10</sup><https://get.google.com/tango>, Abruf: 28.10.2016

um eine möglichst exakte Positionierung im dreidimensionalen Raum zu ermöglichen. Dieses Verhalten lässt sich Abbildung 2.9 entnehmen, wobei der Blickwinkel auf die Referenzpunkte das Bestimmen der genauen Position ermöglicht. Das Driften der Beschleunigungssensoren wird dabei durch die Wiedererkennung von Referenzpunkten im Raum regelmäßig korrigiert und bereits ermittelte Positionen des Geräts werden angepasst<sup>11</sup>. Ebenfalls vorteilhaft an einer Kameranutzung zur Positionierung ist, dass durch die aktive Bedienung des Geräts Wegpunkte direkt im Kamerabild angezeigt und somit die Orientierung für den Nutzer gegenüber anderen Lösungen deutlich erleichtert werden kann, wie in Bild 2.10 zu sehen ist.



Abbildung 2.9: Positionierung anhand optischer Orientierungspunkte<sup>12</sup>




Abbildung 2.10: Einblenden der Wegpunkte in das Kamerabild<sup>13</sup>

Da für eine optische Erkennung das Smartphone aktiv genutzt werden muss, ist es für einen Ansatz, der potenziell im Hintergrund stattfinden und das Bereitstellen von standortbasierten Diensten für den Nutzer automatisieren soll, trotz der äußerst hohen Genauigkeit jedoch nicht

<sup>11</sup><https://developers.google.com/tango/overview/area-learning>, Abruf: 26.11.2016

<sup>13</sup><https://events.google.com/io2016/schedule?sid=5ad50c09-0cef-e511-a517-00155d5066d7#day1/5ad50c09-0cef-e511-a517-00155d5066d7>, Abruf: 26.11.16

<sup>13</sup>ebd.

geeignet und wird daher nicht weiter aufgegriffen.

## 2.6 Barometer

Das Barometer nimmt unter den Sensoren ebenfalls eine Sonderrolle ein, da es Druckunterschiede ermittelt, die normalerweise nicht auf einer Fläche, sondern nur über die Höhe auftreten. Es kann daher grundsätzlich nur zur Bestimmung der Etage oder ähnlichem genutzt werden.




Abbildung 2.11: Druckverteilung über die Etagen eines Hochhauses [XWQ<sup>+</sup>15]

Laut Muralidharan et al. (vgl. [MKM<sup>+</sup>14]) ist ein Bestimmen des absoluten Stockwerks auf der Basis des Luftdrucks praktisch nicht möglich, die relative Änderung des Stockwerks lässt sich jedoch mit hoher Genauigkeit ermitteln. Dies wurde von Xia et al. (vgl. [XWQ<sup>+</sup>15]) belegt. Aus der Beobachtung über knapp drei Wochen hinweg folgerten die Autoren zudem, dass eine Schätzung der Stockwerkhöhe für die Etagererkennung nicht sinnvoll sei, und befassten sich stattdessen mit den Druckabfällen beim Etagenwechsel. Die in einem Hochhaus gemessenen Druckabfall-Muster sind in Abbildung 2.11 erkennbar, wobei jeder waagerechte Block eine der 27 Etagen widerspiegelt und das Gebäude vom Dachgeschoss bis in den Keller abgelaufen

wurde.

Mit der absoluten Erkennung der Etage beschäftigten sich Shen et al. (vgl. [SCZ<sup>+</sup>15]), die hierfür im System BarFi Barometer-Messwerte mit WiFi-Signalsignaturen kombiniert. Durch die Kombination wurde darüber hinaus im Nachhinein selbst Geräten ohne Barometer die Erkennung des Stockwerks ermöglicht.

In IndoorGPS wird das Barometer nicht benutzt, da zum aktuellen Zeitpunkt stets nur auf einer Etage geortet wird. Bei der Etagenbestimmung handelt es sich um ein relativ leicht zu implementierendes Verfahren, sodass einer Erweiterung des Systems in Zukunft grundsätzlich nichts im Weg steht.

## 2.7 Schall

Dank in Smartphones integrierter Lautsprecher und Mikrofone ist auch Schall eine für die Ortung geeignete Signalquelle. Ähnlich der optischen Positionierung ist es auch möglich, jene mit Schall in mehrere Kategorien einzuteilen. Eine Unterscheidung lässt sich in infrastrukturfreie und infrastrukturbasierte Systeme treffen, letztere können wiederum in vom Smartphone aussendende und empfangene Systeme unterteilt werden.

Filonenko et al. (vgl. [FCC13]) nutzten den Lautsprecher eines Smartphones und im Raum installierte Mikrofone, um mit Ultraschallsignalen eine Positionierung mit einer Genauigkeit von unter einem Meter zu erreichen. Der grundlegende Aufbau des Versuchs kann Grafik 2.12 entnommen werden. Durch Multilateration (siehe auch Kapitel 3.1.1), in diesem Fall mithilfe der vier Mikrofone M1 bis M4, kann die Laufzeit des Schalls zur Entfernungsberechnung und damit der Position des Smartphones genutzt werden. Es handelt sich damit um ein infrastrukturbasiertes Ortungssystem, das mit vom Smartphone ausgesendetem Schall arbeitet.

Das gegenteilige infrastrukturbasierte Prinzip verfolgen Systeme wie Active Bat (vgl. [Kar15, p.46]). Hierbei werden Ultraschall-Beacons im Ortungsbereich verteilt angebracht und durch die Entfernungsberechnung eine Positionierung mit Genauigkeiten von wenigen Dezimetern erreicht. Dies liegt zwar deutlich unter der Erkennung optischer Systeme, ermöglicht jedoch ebenfalls eine kostengünstigere Ausstattung (vgl. [MPS14]).




Abbildung 2.12: Ortung eines Smartphones durch eigenes Ultraschallsignal [FCC13] [Bezeichnungen entfernt]

Das Gebiet der infrastrukturfreien Ortung durch Schall wird vergleichsweise selten in Systemen berücksichtigt, was mit der geringen Differenzierbarkeit und der hohen Fluktuation von Alltagsgeräuschen im Zusammenhang stehen könnte. Azizyan et al. (vgl. [ACRC09]) haben im SurroundSense System eine Vielzahl an akustischen Fingerabdrücken der Umgebung mit den Sensoren eines mobilen Endgeräts aufgenommen, was in Abbildung 2.13 dargestellt ist, und hierbei die Ortung via Umgebungsgeräuschen getestet.

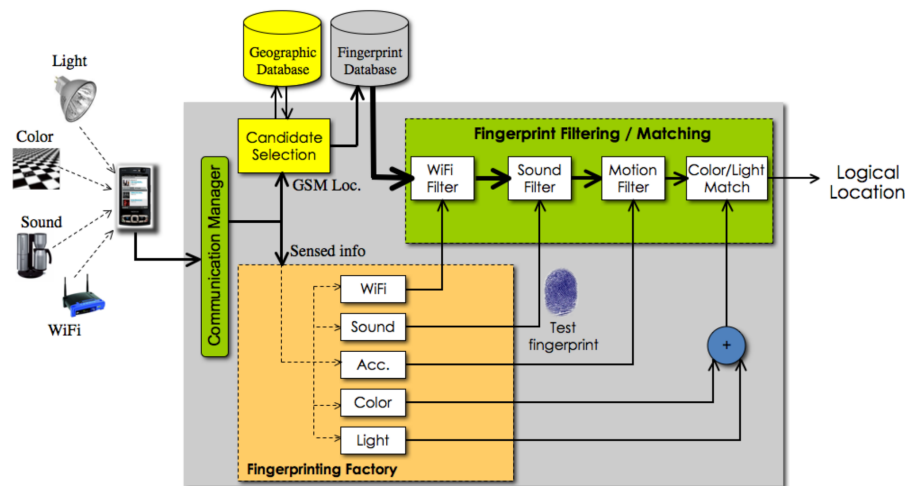


Abbildung 2.13: Fusion der Sensordaten bei SurroundSense [ACRC09]

Hierzu nahmen die Autoren über den Verlauf einer Minute die Geräusche des Orts auf, um anschließend mithilfe der schnellen Fourier Transformation einen akustischen Fingerabdruck bilden zu können. Da hiermit keine ausreichende Differenzierbarkeit gewährleistet werden konnte, um eine zufriedenstellende Ortung zu ermöglichen, wurde auf die durchschnittliche Amplitude als Hauptunterscheidungsmerkmal der Umgebung zurückgegriffen. Die hierauf basierenden Signaturen sind im Diagramm 2.14 zu finden.




Abbildung 2.14: Amplitudenbasierte Fingerabdrücke dreier Umgebungen [ACRC09]

Da die Umgebungsgeräusche stark im Verlauf der Zeit fluktuierten, sahen Azizyan et al. von einer rein auf Schall setzenden Ortung ab und nutzten diesen nur als zusätzlichen Filter, um nicht übereinstimmende Orte ausschließen zu können.

Einen anderen Weg schlugen Tarzia et al. [TDDM11] mit dem System Acoustic Background Spectrum ein. Während auch in dieser Arbeit akustische Fingerabdrücke von Räumen erstellt und anhand dieser die Unterscheidung vorgenommen wurde, diente die Fourier Transformation diesmal dazu, die leisesten Umgebungsgeräusche, in diesem Fall die über die Zeit nicht veränderlichen Töne niedriger Frequenzen (bis sieben kHz), aufzuzeichnen und hiermit einen hohen Wiedererkennungswert zu schaffen. Im Gegensatz zum SurroundSense Projekt ist mit



diesem Ansatz die raumweite Positionierung gelungen. Problematisch wird die Ortung jedoch, sobald viele Räume unterschieden werden sollen oder sich Menschenmengen innerhalb der Räume aufhalten. Gemeinsam mit einer vergleichsweise langen Einmesszeit spricht dies gegen den Einsatz der Technik in der ersten Softwareiteration von IndoorGPS, es handelt sich allerdings um eine sinnvolle Ausbaustufe und sollte daher für Weiterentwicklungen als zusätzlicher Differentiator im Fokus behalten werden.

## 3 Positionierungsverfahren und Filterungsarten

Für das erfolgreiche Orten eines Smartphones ist neben dem Wissen über die verbauten Sensoren eine Übersicht über die nutzbaren Positionierungsverfahren wichtig. Das vorliegende Kapitel hat daher das Aufzeigen von Wegen zum Ziel, die für eine erfolgreiche Ortung gegangen werden können, um die in Kapitel 2 angedeuteten Hürden nehmen zu können.

Die eigentliche Positionierung lässt sich in eine absolute und eine relative Vorgehensweise unterscheiden. Bei der absoluten Positionierung wird dabei pro Zeitschritt direkt mit einer Position ohne zwingendes Wissen über den vorherigen Aufenthaltsort gearbeitet. Je nach Vorgehen kann der Vorbereitungsaufwand für die Lokalisierung gegenüber der relativen Art deutlich höher sein, da die Umgebung für eine absolute Positionierung bekannt und entsprechend hinterlegt werden muss. Während sich die dabei aufkommende Datenmenge bei der Triangulation (siehe Kapitel 3.1.1) meist noch in Grenzen hält, besteht besonders beim Fingerprinting (siehe Kapitel 3.1.2) die Gefahr, dass sowohl der Aufwand des Einmessens als auch der Suchraum der Messwerte bei der Ortung linear mit der Größe des Gebiets anwächst. Aus diesem Grund kann hierbei ein Clustering (siehe Kapitel 3.6) und das Beschränken auf einen Teil dieser Wertegruppen sinnvoll sein.

Die relative Positionierung arbeitet hingegen mit der Abweichung zur zuletzt bekannten Position, die damit jederzeit zwingend bekannt sein oder neu bestimmt werden muss, was eine Positionierung auch in unbekanntem Umgebungen ermöglicht. Durch das rekursive Vorgehen kann diese zwar pro Zeitschritt teilweise mit wenig Rechenzeit ermittelt werden, leidet aber prinzipbedingt unter dem akkumulierenden Fehler und damit einer sich kontinuierlich verstärkenden Drift. Um dem entgegenzuwirken wird zum einen die Beschränkung auf kurze Distanzen empfohlen (vgl. [Gut00]), zum anderen kann eine effektive Filterung (siehe Kapitel 3.5) sinnig sein. Hinzu kommt, dass Positionen in unerreichbaren Bereichen erkannt und verworfen werden müssen.

Wie schon im Rahmen des Hauptseminars [Bar16a] beschrieben, kann auch eine Kombination aus absoluter und relativer Ortung denkbar sein und in gewissen Situationen eine lohnenswerte Alternative zu den einzelnen Vorgehen darstellen. So ließe sich ein Standort mittels absoluter Positionierung ermitteln, als Grundlage für die relative Positionierung setzen und das Wissen über die kontinuierliche Abweichung in Folgeschritten für eine höhere Genauigkeit nutzen. Die während der relativen Positionierung auftretende Drift kann wiederum durch neue absolute Positionen regelmäßig korrigiert werden (vgl. [FH13]).

IndoorGPS nutzt in der aktuellen Ausbaustufe die absolute Ortung, wofür die folgenden Kapitel eine Entscheidungsgrundlage bilden. Eine sinnvolle Ergänzung durch relative Positionierungsmethoden und die sich hieraus ergebenden Möglichkeiten wie SLAM (siehe Kapitel 3.3) oder bessere Filtermethoden (siehe Kapitel 3.5) werden hingegen herausgearbeitet und für die Weiterentwicklung des Projekts in Ausblick gestellt.

## 3.1 Absolute Ortung

Das Erfassen der Position mittels absoluter Ortung lässt sich erneut in zwei Arten einteilen. Auf der einen Seite kann sie mit der Bestimmung der Abstände und Einfallswinkel zwischen Sender und Empfänger durch Trilateration beziehungsweise Triangulation erfasst werden. Ein Problem der Methode ist, dass die Position der Sender bekannt sein und in den Grundriss oder eine vergleichbare Karte eingetragen werden muss, was nicht in jedem Fall möglich ist.

Demgegenüber steht das Sammeln und Abgleichen von Signal-Fingerabdrücken, dem sogenannten Fingerprinting. Das Eintragen der Senderpositionen entfällt hierdurch zwar, allerdings muss vor der Ortung der gesamte Bereich, in dem die Lokalisierung stattfinden soll, kleinschrittig und bestenfalls mehrfach eingemessen werden. Mehr zu den Vor- und Nachteilen des Fingerprintings findet sich im Kapitel 3.1.2.

### 3.1.1 Triangulation und Trilateration

Beim Empfang von Signalen lässt sich von der Signalstärke auf die Entfernung zwischen Sender und Empfänger sowie von Laufzeitunterschieden an den Antennen im Empfangsgerät auf den Einfallswinkel schließen. Dieses Wissen kann für die Triangulation oder Trilateration genutzt

und somit die ungefähre Position des Nutzers berechnet werden.

Abbildung 3.1 zeigt die beiden sich ähnelnden Methoden. Wird bei der Trilateration (linkes Bild) nur die Entfernung zu den Sendern P1 und P2 genutzt, um auf die Positionen schließen zu können, kommen sowohl Position A als auch B in Frage. Diese Mehrdeutigkeit wird aufgelöst, sobald mehr als zwei sich überschneidende Entfernungskreise zu entsprechenden Sendern aufgespannt werden können. Im Beispiel bleibt daher nur Position B als möglicher Ort.




Abbildung 3.1: Triangulation und Trilateration<sup>1</sup>

Analog zur Trilateration kann die Position bei der Triangulation auch mit den Winkeln zu allen angrenzenden Sendern bestimmt werden. Da die Position der Sender bekannt ist, reichen theoretisch bereits zwei von ihnen für die Bestimmung. Die Genauigkeit nimmt allerdings bei mehreren Sendern deutlich zu, weshalb auch bei der Triangulation auf möglichst viele WiFi-Accesspoints, Bluetooth-Geräte oder ähnliches gesetzt werden sollte.

Problematisch in der Praxis ist neben der notwendigen Bekanntheit aller Senderpositionen vor allem Verfälschungen der Signalstärken. Dies kann etwa durch Reflexionen an Wänden geschehen, wodurch auch nahe Sender als weit entfernt interpretiert werden. Auch feuchte Luft und vor allem der menschliche Körper durch seinen hohen Wassergehalt verfälschen das Signal stark und führen zu fehlerhaften Positionen. Für gute Ergebnisse werden also eine möglichst

---

<sup>1</sup>Trilateration: <https://de.wikipedia.org/wiki/Lateration>, Abruf: 23.12.16, Triangulation: <http://mathworld.wolfram.com/TriangulationPoint.html>, Abruf: 11.11.16

freie Sicht zwischen Sender und Empfänger benötigt. In Außenarealen ist dies oft annähernd gegeben, in Innenräumen durch Wände und Hindernisse allerdings prinzipbedingt kaum möglich.

Darüber hinaus kann es zu Messungenauigkeiten kommen, die zu einem Versatz der Position in unereichen Umgebungen wie Wände, einen Bereich außerhalb des Gebäudes oder Ähnlichem führen. Zusätzlich zur reinen Positionierung sollte daher noch das Herausfiltern ebensolcher Versätze hinzukommen.

Probleme wie diese führen dazu, dass sich das Fingerprinting als die genauere Positionierungstechnik mit Smartphones herausgestellt hat (vgl. [FH13], [HS15]) und daher in IndoorGPS auf Trilateration und Triangulation verzichtet wird.

#### 3.1.2 Fingerprinting

Statt durch Abstands- oder Winkelbestimmung direkt auf die Position zu schließen, ist das Vorgehen beim Fingerprinting, dass in einer Offline-Phase vorher die Umgebung vermessen und Signalsignaturen (die namensgebenden „Fingerprints“) gesammelt werden. Anschließend geschieht in der Online-Phase ein Vergleich der aktuellen Messwerte mit den bereits gespeicherten und das indirekte Bestimmen der Position über denjenigen Punkt, beziehungsweise diejenigen Punkte mit der geringsten Abweichung im Werteraum. Schematisch wird dies in Abbildung 3.2 anhand der empfangenen WiFi-Signalstärke gezeigt (in der Grafik „Received Signal Strength Indicator“, kurz „RSSI“ genannt).

Die Nachteile von Triangulation und Trilateration verringern sich deutlich beim Fingerprinting, da weder auf Laufzeitunterschiede oder Entfernungen geschlossen wird, noch physikalisch nicht erreichbare Positionen gefiltert werden oder die Positionen der Sender bekannt sein müssen. Stattdessen werden die empfangenen Signale direkt dem Ort zugeordnet, an dem sie gemessen wurden. Ein Nachteil des Fingerprintings ist die zwingend erforderliche und unter Umständen äußerst zeitaufwändige Offline-Phase, die jedoch langfristig durch das Kartieren der Umgebung während der Ortung (siehe Kapitel 3.3) vermieden werden könnte.

Bekanntheit erlangte das Fingerprinting durch das RADAR-System [BP00], das mittlerweile die Grundlage für den Großteil der auf Fingerprinting setzenden Verfahren bildet (vgl. [SCZ<sup>+</sup>15, S. 416]). RADAR prägte das Vorgehen der „Offline Phase“, während der das Gebäude

---

<sup>2</sup><http://www2.ucy.ac.cy/~laoudias/pages/penek/description.html>, Abruf: 12.10.16

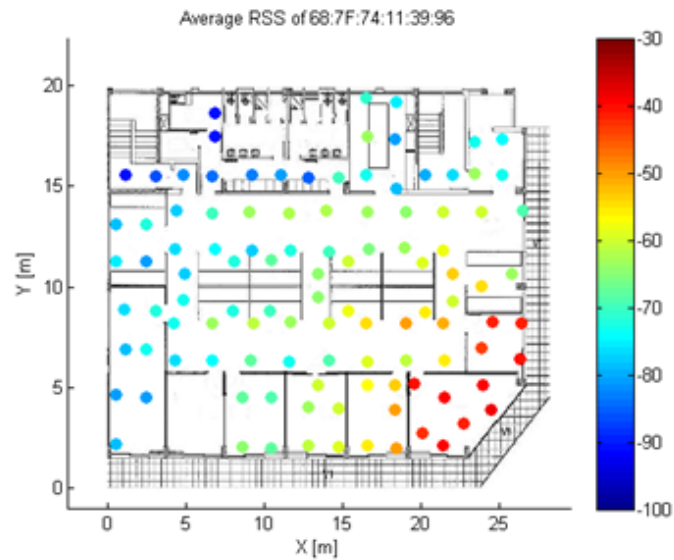


Abbildung 3.2: Vereinfachte Darstellung des Fingerprintings<sup>2</sup>

abgeschriftet und Signalstärken einem Ort zugewiesen werden, sowie der „Online Phase“ (in RADAR noch „Realtime Phase“ genannt), in der die eigentliche Positionierung stattfindet.

Die (WiFi-)Daten werden bei RADAR in Vektoren gespeichert, die jeweils den Access Point und dessen Signalstärke enthalten. Das Ergebnis entspricht einem Vektorfeld, bei dem die Vektoren Koordinaten zugeordnet werden, die der Nutzer zu Beginn festlegt und während der Messung abschreitet. Darüber hinaus wird an jeder Koordinate ebenfalls die Orientierung gespeichert und so jede der vier Himmelsrichtungen mit Signalstärken versehen. Dieses Vorgehen verbessert zwar die Genauigkeit des Systems, erhöht jedoch auch deutlich die Zeit, die in der Offline Phase zum Einmessen benötigt wird.

Um den Ort des Nutzers ermitteln zu können, findet in RADAR ein Vektorvergleich zwischen der aktuellen Messung am Gerät und sämtlichen gespeicherten Messungen statt. Hierfür wird anhand der euklidischen Distanz die Nähe zu jedem Vektor berechnet und anschließend die Koordinate mit dem ähnlichsten Vektor als Position angenommen. Da die Nähe sich auf die Ähnlichkeit der Signale bezieht, erhielt das Vorgehen in RADAR den Namen „Nearest Neighbor in Signal Space“. Eine nähere Beschreibung der Distanzberechnung, die in IndoorGPS eingeflossen ist, findet sich in Kapitel 3.4.

Viele der in RADAR genutzten Verfahren, wie die Aufnahme der Messergebnisse in Vektorform, haben sich mittlerweile etabliert und wurden, teils in vereinfachter oder abgeänderter Variante, auch für IndoorGPS übernommen. Ein Vorteil gegenüber RADAR ist dabei, dass sowohl Messung als auch Planung der abzuschreitenden Wege am selben Gerät stattfinden. Die manuelle Verknüpfung von Vektoren und Koordinaten entfällt daher und wird durch gleichmäßiges Verteilen der Messpunkte auf die abgeschrittenen Pfade ersetzt. Weiterhin wird das Einmessen mehrerer Himmelsrichtungen vereinfacht, indem der gesamte Pfad einmal hin und schließlich wieder zurück abgegangen wird. Somit werden zwar nicht alle Orientierungen beachtet, allerdings ein Kompromiss aus Datenqualität und Zeitaufwand geschlossen.

Das Vorgehen, den im Signalraum nächsten Vektor als Position anzunehmen, wurde zum einen in unveränderter Weise als ungefilterte Ortung übernommen, zum anderen durch Verrechnung mehrerer nächster Vektoren als gefilterte Ortung. In diesem Rahmen wird das Verfahren im Kapitel 3.5.1 vorgestellt.

Neben dem in RADAR genutzten deterministischen Ansatz, Signaturen zu sammeln und sich bei der Positionierung ausschließlich auf den Vergleich mit diesen Signaturen zu beziehen, existiert mit dem probabilistischen Ansatz noch ein weiterer Weg zur Positionierung. Anhand der Messungen wird bei diesem Ansatz auf die Charakteristik der Signalausbreitung geschlossen und hiermit ein Histogramm erstellt, vereinfacht zu sehen in Abbildung 3.3, das die Signalverteilung über das abgeschrittene Gebiet abbildet. Vorteile probabilistischer Verfahren sind eine im Schnitt höhere Genauigkeit und der Wegfall der Einschränkung deterministischer Verfahren, dass die Positionierung nur an diskreten Orten stattfinden kann (vgl. etwa [YAS03]). Durch die Bestimmung des Ausstrahlverhaltens und die Interpolation zwischen den Messpunkten lassen probabilistische Verfahren die Ortung über die gesamte Fläche zu.

Größere Bekanntheit erlangte der Ansatz im Projekt HORUS [YA05], das entwickelt wurde, um die Genauigkeit gegenüber Systemen wie RADAR zu verbessern. Um die Charakteristik ausreichend genug erfassen zu können, werden für HORUS über mehrere Minuten hinweg Messungen am selben Ort vorgenommen und damit Schwankungen im Laufe der Zeit ausgeglichen. Anstatt ganze Pfade abzuschreiten wird also auf eine punktuelle, aber längerfristige Einmessung zurückgegriffen.

Um auf die Position des Nutzers schließen zu können, wird bei probabilistischen Verfahren anstatt des geringsten Abstands zwischen der aktuellen Messung und den gespeicherten

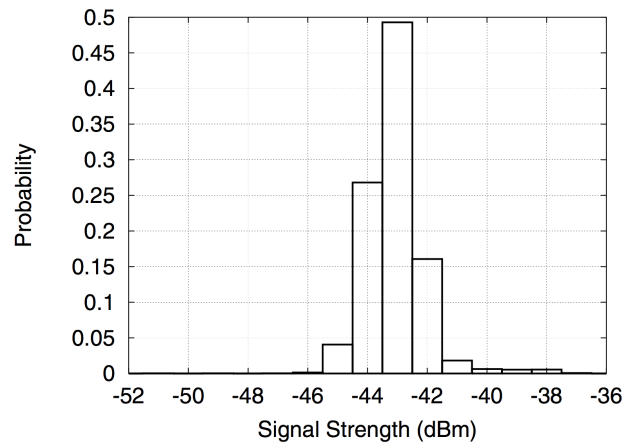


Abbildung 3.3: Wahrscheinlichkeitsverteilung eines Funksignals [YA05, S. 206]

Messungen nach dem Ort gesucht, an dem der aktuelle Messwert mit der höchsten Wahrscheinlichkeit auftreten würde (siehe Formel 3.1). Die höchste Wahrscheinlichkeit entspricht dabei dem Produkt der Auftretswahrscheinlichkeiten der einzelnen Signalstärken (siehe Formel 3.2).

$$\operatorname{argmax}_x P(x|s) = \operatorname{argmax}_x P(s|x) \quad (3.1)$$

$$P(s|x) = \prod_{i=1}^k P(s_i|x) \quad (3.2)$$

[YA05, S. 209]

Für die Berechnungen wird dabei auf das Bayes-Theorem zurückgegriffen. Es beschreibt die Bestimmung der Wahrscheinlichkeit eines Ereignisses, dem ein weiteres Ereignis vorausgegangen ist, indem ihre umgekehrte Reihenfolge als Grundlage genommen wird (vgl. [Vap98]). Hierdurch kann aus der Signalverteilung auf den Ort geschlossen werden, da in der Offline-Phase zuvor aus dem Ort auf die Signalverteilung geschlossen, genauer die Signale an jenem Ort aufgenommen wurden.



Mit dem Vorhaben, die Genauigkeit zu verbessern, waren die Autoren Youssef und Agrawala zwar erfolgreich - die durchschnittliche Genauigkeit erhöhte sich in Tests gegenüber RADAR von etwa 3,6-4m auf rund 0,4-0,65m[[YA05](#), 215]. Gleichzeitig erhöhte sich jedoch auch der Einmessaufwand in erheblichem Maße, da für die Erfassung der Charakteristik mehrerer WiFi-Netze Proben über eine bedeutend längere Zeitspanne notwendig waren, was grundsätzlich auch für andere probabilistische Verfahren gilt (vgl. [[PZZ<sup>+</sup>16](#), S. 4]).

Systeme nach probabilistischem Ansatz stellen normalerweise hohe Leistungsanforderungen ans Gerät, was besonders für Smartphones nachteilig ist. In HORUS wird deshalb die Ortung mit einem Clustering kombiniert, um die Rechenlast zu begrenzen. Dieses Thema und seine Notwendigkeit für deterministische Verfahren sowie IndoorGPS werden in Kapitel [3.6](#) weiter behandelt.

Eine aktuelle Entwicklung im Bereich der Signalanalyse beim Fingerprinting ist, die Charakteristika der empfangenen Kanäle zu untersuchen, anstatt nur einzelne Signalstärken bei der Berechnung zu beachten. Hiermit werden die Auswirkungen von Reflexionen und Signaländerungen über den zeitlichen Verlauf reduziert, was zu einer deutlichen Verbesserung von Genauigkeit und Zuverlässigkeit führt. Als Beispiele seien hier das in Kapitel [2.2](#) vorgestellte Chronos, das in Kapitel [2.1](#) genannte Time & Code Division-Orthogonal Frequency Division Multiplexing oder das Fine-grained Indoor Fingerprinting System (vgl. [[XWYN12](#)]) genannt, die allesamt Erkennungen in Genauigkeitsbereichen von unter einem Meter ermöglichen. Mit ihrer hohen Komplexität sowie den benötigten Geräte- und Infrastrukturanpassungen bilden sie allerdings eher die Basis einer Weiter-, beziehungsweise Eigenentwicklung und kommen nicht in IndoorGPS zur Geltung.

Auch vom Einsatz probabilistischer Verfahren im Praxisteil dieser Arbeit wird vorerst abgesehen, da deterministische Ansätze weniger hohe Leistungsanforderungen an das Gerät stellen, niedrigere Einmesszeiten voraussetzen und damit schnellere Iterationen zulassen, kein Backend erfordern und schließlich technisch einfacher umzusetzen sind. Besonders die in Kapitel [3.4](#) vorgestellte, simple Modularisierung durch Normalisierung der Sensorwerte ist mit probabilistischen Methoden, bedingt durch unter Umständen deutlich unterschiedliche oder fehlende Ausstrahlverhalten, nicht in ähnlichem Maße durchführbar. In den Messungen in Kapitel [4.4](#) wird sich herausstellen, dass diese Entscheidung unter gewissen Bedingungen ausreicht, um raumweite Genauigkeiten erreichen zu können, weshalb die Nutzung probabilis-

tischer Verfahren nur für die Weiterentwicklung des Projekts in Aussicht gestellt wird.

Auffällig ist, dass sich ein großer Teil der Arbeiten im Fingerprinting-Bereich ausschließlich auf die Ortung via WiFi beschränkt und die Sensor-Fusion wenig bis gar nicht beachtet (vgl. [BYG<sup>+</sup>15]). Bozkurt et al. (vgl. ebd.) erstellten aus diesem Grund eine Fingerprinting Datenbank für Forschungszwecke, die sowohl WiFi- als auch Bluetooth- und Magnetfeldsignaturen enthält. Als grundsätzliches Ziel solcher Fused Sensor Datenbanken gaben sie an, dass diese für viele Problemarten mit sich ändernden Umgebungen eine genauere und robustere Möglichkeit gegenüber solchen Datenbanken darstellen, die sich auf einzelne Sensoren beschränken. Arbeiten wie die genannte unterstreichen das Vorgehen in IndoorGPS, die Erkennung beim Fingerprinting entgegen vieler Systeme nicht allein auf WiFi, sondern mehrere Sensoren zu stützen.

## 3.2 Relative Ortung

Wie bereits in Kapitel 2.4 angerissen, lassen sich Gyroskop und Beschleunigungssensor nutzen, um mittels Koppelnavigation die relative Ortung mithilfe eines Smartphones zu gewährleisten. Grafik 3.4 stellt das Positionieren mit Koppelnavigation dar: Von der Ursprungsposition aus wird zum einen anhand der Beschleunigung eine Positionsabweichung ermittelt, zum anderen in welche Richtung diese vorstatten geht. Anschließend wird die berechnete Position wieder als Ursprung angenommen und die Berechnung wiederholt.

Hierzu wird innerhalb von Gebäuden das Gyroskop in der Regel dem Kompass vorgezogen, da die in Kapitel 2.3 angesprochenen Störungen der Magnetfeldsignaturen zum Beispiel durch den Eisenkern einiger Wände die Genauigkeit der Orientierung stark beeinflussen kann (vgl. [KH15]). Arbeiten wie SmartPDR (ebd.) nutzen hingegen beide Sensoren, um auf geraden Strecken die Erkennung des Gyroskops zu verbessern und bei verfälschten Ergebnissen des Kompasses besonders während eines Richtungswechsels dessen Messungen verwerfen.

Da Sensoren prinzipbedingt nur eine begrenzte Genauigkeit aufweisen, driftet die gemessene Position nach einiger Zeit durch einen akkumulierenden Fehler zwangsweise von der tatsächlichen Position ab. Aus diesem Grund sollte die kontinuierliche Nutzungszeit der Koppelnavi-

---

<sup>3</sup><http://www.slideshare.net/iatchisin/implementing-deadreckoning-on-a-mobile-ground-robot-using>, Abruf: 27.11.16




Abbildung 3.4: Funktionsweise der Koppelnavigation<sup>3</sup>

gation so kurz wie möglich ausfallen und regelmäßig auf eine bekannte Position zurückgesetzt werden.

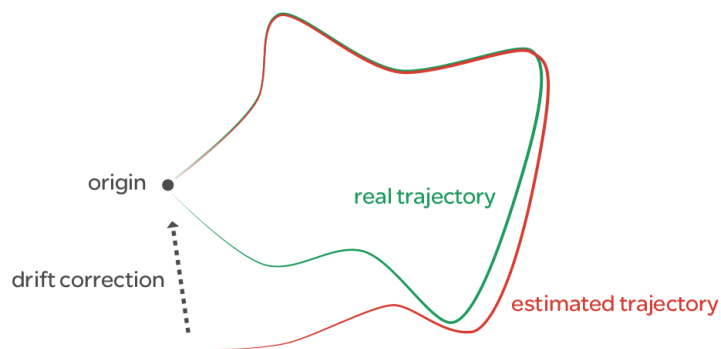


Abbildung 3.5: Driftkorrektur nach Loop Close [Pfeile des Koordinatensystems entfernt]<sup>4</sup>

Abbildung 3.5 zeigt das Abweichen von der tatsächlichen Position und die anschließende Driftkorrektur, die beim erneuten Erreichen einer bekannte Position geschieht. Bei einem solchen „Loop Close“ genannten Vorgehen werden die bis zu diesem Punkt gemessenen Positionen jeweils um den anteiligen Versatz zwischen der wiedererkannten Anfangsposition

<sup>4</sup><https://developers.google.com/tango/overview/area-learning>, Abruf: 13.12.16

und der ermittelten Endposition verschoben. Um zu erkennen, dass Anfangs- und Endpunkt ein und denselben Ort beschreiben, ist aufgrund des zwingend auftretenden Messfehlers eine zusätzliche Erkennungsart notwendig (vgl. [Har13]).

Ein besonderer Vorteil ist, dass beim Ausfall aller Funksensoren, wenn etwa keine Sender in Reichweite sind oder der Flugmodus aktiviert wurde, die relative Ortung als Fallback genutzt werden kann. Somit ist zudem keinerlei Infrastruktur vonnöten, was die Nutzung äußerst kosteneffizient macht. Selbst wenn die Genauigkeit im Laufe der Zeit mangels Loop Close durch absolute Ortung deutlich abnehmen dürfte, wäre eine grobe Ortung weiterhin sichergestellt. Einige Systeme (vgl. [TDDM11], [WSE<sup>+</sup>12]), arbeiten darüber hinaus mit dem Wiedererkennen von Orten ohne Funksignale und kommen damit dauerhaft ohne diese aus.

Relative Ortung kann ebenso dazu genutzt werden, Energie zu sparen, indem bei Nichtbewegen des Geräts, erkennbar an einem inaktiven Schrittzähler, die Zeit zwischen den Messungen erhöht wird. Diese Optimierung findet in IndoorGPS Anwendung und wird in Kapitel 4.2.2 erläutert. Darüber hinaus werden für die Verteilung der Messungen beim Fingerprinting, wie es aktuell in IndoorGPS genutzt wird, Punkte in gleichmäßigem zeitlichen Abstand aufgezeichnet und anschließend, nach dem Abschreiten eines Pfads, äquidistant auf diesem verteilt. Dieses arbeitsintensive Vorgehen ließe sich mithilfe der relativen Ortung optimieren, indem die Signale an den entsprechenden Positionen automatisch aufgenommen und hinterlegt werden wie zum Beispiel von Liu et al. (vgl. [LDRZ14]) gezeigt.

Gegenüber den diskreten Positionen, die im deterministischen Fingerprinting unterschieden werden, erlaubt die relative Positionierung eine kontinuierliche Ortung. Aufgrund des Bewegungsmodells kann zu jedem Zeitpunkt auf Basis der vorhergehenden Bewegungen ein neuer Ort geschätzt werden, was in rekursiven Filtern, wie dem Kalman Filter oder dem Partikel-Filter, die in Kapitel 3.5.2 respektive 3.5.3 beschrieben werden, genutzt wird, um die Messergebnisse zu verbessern.

Hybride Systeme, also solche, die die relative Ortung mit der absoluten verbinden, ermöglichen darüber hinaus das Nutzen von Techniken, die die Vorteile beider Verfahren dazu verwenden, die jeweiligen Nachteile auszugleichen. Das folgende Kapitel behandelt mit SLAM einen bekannten Ansatz dieser Art.

### 3.3 SLAM

Trotz der genannten Vorteile, die das Fingerprinting gegenüber Vorgehen wie der Multilateration bietet, ist ein großer Nachteil die einmalige, zeitaufwändige und arbeitsintensive Einmessung von Signalsignaturen und die hieraus resultierenden Folgen. Diese sind unter anderem (vgl. [HS15, S. 3]):

- Statische Fingerprints sind anfällig gegenüber Umweltveränderungen.
- Fingerprints bleiben nicht zwingend über den Zeitverlauf stabil und benötigen daher im besten Fall regelmäßige Rekalibrierung.
- Das Einmessen ist nur im kleinen Rahmen skalierbar, aufwändiger wird es in Gebäudekomplexen wie Einkaufszentren oder Büros.
- Die Positionierung ist unter Umständen abhängig vom Gerätetyp und die Fingerprints damit nicht allgemeingültig mit nur einem Gerät einmessbar.

Die Offline-Phase, die vor der eigentlichen Positionierung stattfindet, steht einer über weite Nutzerkreise skalierenden Akzeptanz und der vollautomatisierten Nutzung im Hintergrund im Weg. Um diese Herausforderung anzugehen, lässt sich „Simultaneous Localization and Mapping“, kurz „SLAM“, nutzen.

Das aus der Robotik stammende Prinzip (vgl. [Har13]) wird dazu genutzt, die Wegfindung in bisher unbekanntem Gebiet zu ermöglichen, indem während der Orientierung bereits eine Karte der Umgebung angefertigt wird. Diese Karte kann anschließend zur Lokalisierung mittels Fingerprinting oder zum Rekalibrieren bei der Koppelnavigation genutzt werden. Doch nicht nur die Offline-Phase wird hierdurch obsolet. Es können darüber hinaus auch während der Laufzeit des Systems Schwankungen der Signale, die durch Umweltveränderungen oder das Verschieben von Möbeln und so weiter auftreten, durch ständiges Neuscannen über längere Zeiträume hinweg ausgeglichen werden.

Für SLAM können mehrere Verfahren genutzt werden, eines hiervon ist die Koppelnavigation. Da für diese eine bekannte Umgebung keine Voraussetzung ist, kann vom letztbekanntesten oder einem festgesetzten Ort die Navigation direkt starten. Während des Abschreitens werden nun fortlaufend Signalsignaturen gesammelt und der ermittelten Position zugeordnet. Sobald eine bereits bekannte Position erreicht wird, kann mittels Loop Close zum einen eine Driftkorrektur vorgenommen und die Positionen der Signaturen verbessert werden (vgl. [WSE<sup>+</sup>12]);

zum anderen aber auch ab diesem Zeitpunkt die absolute Positionierung solange genutzt werden, bis wieder unbekanntes Terrain betreten wird (vgl. [FH13]).

Zu diesem Zeitpunkt können nun verschiedene Strategien verfolgt werden. So könnte der Fokus auf die Reduzierung des Energieverbrauchs oder die Erhöhung der Genauigkeit gelegt werden. Grundsätzlich sind Prozessorlast und Energieverbrauch bei SLAM im Vergleich zur reinen Online-Phase im Fingerprinting erhöht, da neben der Ortung zusätzlich die Erstellung der Karte vorangetrieben und eine relative Ortung vorgenommen werden muss (vgl. [HS15]). In SmartSLAM (vgl. [FH13]) liegt deshalb der Fokus darauf, je nach Bekanntheitsgrad der Umgebung das Vorgehen zu wechseln und eine Balance zwischen Genauigkeit und Energieverbrauch zu finden. Die Wahl des Verfahrens lässt sich im Ablaufplan der Abbildung 3.6 einsehen.

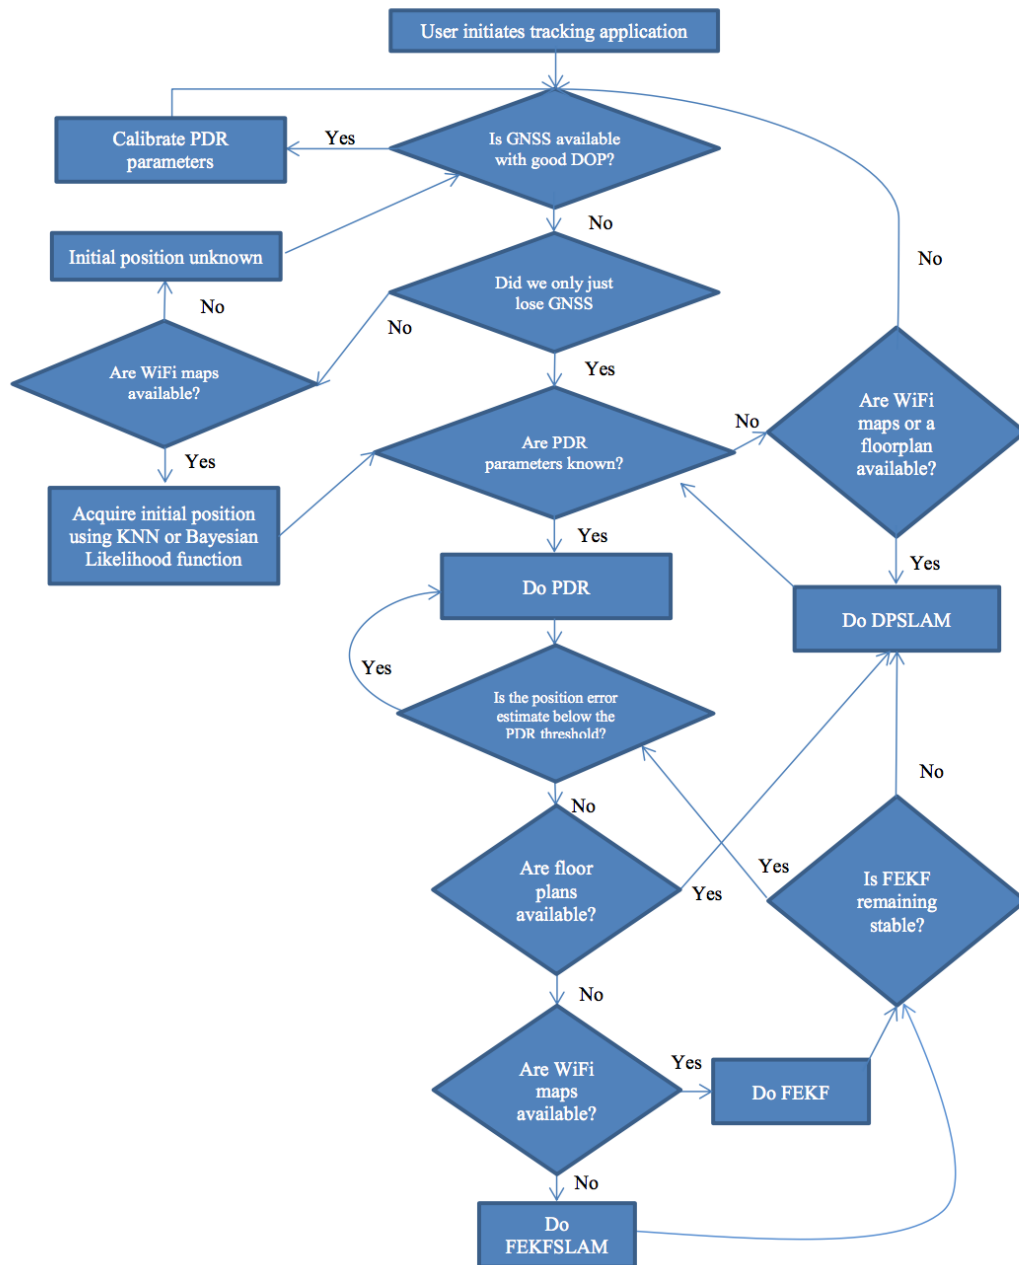


Abbildung 3.6: Ablauf der Verfahrensauswahl bei SmartSLAM [FH13]

Zu Beginn der Ortung wird die relative Ortung von der letztbekanntesten globalen oder durch absolute Ortung ermittelten Position gestartet und solange genutzt, bis der akkumulierende Fehler den Schwellwert übersteigt. Dem folgend wird je nach Verfügbarkeit bereits gesammelter Fingerprints zwischen einem diese nutzenden Filter, einer Erweiterung des Kalman-Filters (siehe Kapitel 3.5.2), dem „Fingerprint Extended Kalman Filter“, reiner relativer Positionierung und zwei SLAM-Arten unterschieden. Dies sind „Fingerprint Extended Kalman Filter SLAM“ als ungenauere, aber leistungsschonende, das Kalman Filter nutzende SLAM Variante und „Distributed Particle SLAM“, das wegen des genutzten Partikel-Filters (siehe Kapitel 3.5.3) leistungshungriger aber auch genauer ist. Durch das Nutzen einer solchen intelligenten Verfahrenswahl entsteht zwar eine deutliche zusätzliche technische Komplexität; gleichzeitig birgt sie aber auch das Potenzial, herkömmlichen SLAM-Systemen gegenüber in Bezug auf Genauigkeit und Energieverbrauch überlegen zu sein.

Neben der Koppelnavigation lassen sich noch weitere Methoden für SLAM nutzen. Eine davon ist Google Tango, das kontinuierlich aufgenommene Bilder der Umgebung auf Referenzpunkte untersucht und mit bereits bekannten Bildern abgleicht, um Umgebungen wiederzuerkennen und die Positionierungsleistung zu erhöhen<sup>5</sup>. Auf diese Weise kann eine sich ständig vergrößernde und verbesserte, dreidimensionale Karte der Umgebung aufgezeichnet werden, die im Anschluss wieder für die Positionierung genutzt wird.

Auch im Crowd Sourcing besteht eine Möglichkeit für SLAM (vgl. [HS15]). Abbildung 3.7 zeigt einen typischen Aufbau eines Crowd Sourcing nutzenden SLAM-Systems. Der Frontend-Teil entspricht dem Smartphone des Nutzers, welches die Signale der Umgebung auf die durch relative Positionierung gesammelten Positionen mappt und fusioniert an ein Backend schickt. In diesem werden die Fingerprints aller Nutzer zusammengefügt und in einer Datenbank hinterlegt, mit deren Hilfe die Positionierung stattfinden kann und dem Nutzer zurückgegeben wird. Entnehmen lässt sich darüber hinaus, dass das Aufsetzen eines funktionierenden Crowd Sourcing Systems durch die Vielzahl teilnehmender Komponenten ein technisch äußerst komplexes Unterfangen darstellt. Für ein Projekt wie IndoorGPS ist es daher im Rahmen dieser Arbeit trotz des hohen Potenzials nicht sinnvoll.

Aus dem Crowd Sourcing Ansatz ergeben sich zudem neue Herausforderungen, wie das Zusammenbringen von Daten unterschiedlicher und unkalibrierter Geräte mit unvorhersehbarer

---

<sup>5</sup>[https://developers.google.com/tango/overview/concepts#area\\_learning\\_overview](https://developers.google.com/tango/overview/concepts#area_learning_overview), Abruf: 13.12.16



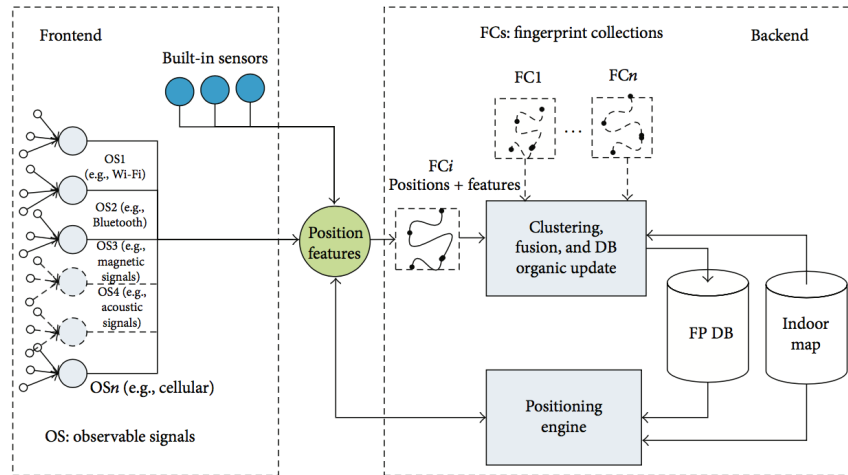


Abbildung 3.7: Typischer Aufbau einer Crowd Sourcing SLAM-Lösung [PZZ<sup>+</sup>16, S. 3]

Sensorqualität (vgl. [PZZ<sup>+</sup>16]). Auch das Ausspionieren von Aufenthaltsorten der Nutzer oder von diesen bewusst falsch gesetzte Messungen werden bisher nicht ernsthaft behandelt und haben das Potenzial, sowohl die Messergebnisse von SLAM-Systemen als auch die Akzeptanz solcher Systeme in in der Praxis deutlich zu verschlechtern (vgl. [HS15]). Beim Aufbau einer Crowd Sourcing Lösung sollten diese Punkte also in jedem Fall mit dem Ziel eines akzeptierten und skalierenden Systems Beachtung finden.

### 3.4 Sensor-Fusion

Wie bereits im Grundprojekt [Bar15] festgestellt, ist die Ortung mit nur einer Sensorart gerade im Smartphonebereich mit seinen besonders kompakten und energiesparenden Sensoren oft weder genau noch sinnvoll, da von einer hohen Fehleranfälligkeit und kaum überwindbaren Nachteilen ausgegangen werden muss: Kameras benötigen ein unverdecktes Sichtfeld, Funksignale werden in Gebäuden und von überlagernden Signalen gestört, die Ortung mit Magnetfeldern ist für sich genommen nicht immer ausreichend und so weiter. Werden für die Positionierung nur einzelne Sensoren des Smartphones genutzt, treten in der Regel starke Schwankungen und Mehrdeutigkeiten auf, die es für eine zuverlässige Ortung zu verhindern gilt. Um die Unsicherheiten der Sensoren und die Mehrdeutigkeiten bei der Positionierung zu reduzieren, werden die Sensoren des Smartphones deshalb miteinander fusioniert.

Mit der Sensorfusion sollen die Vorteile der einzelnen Sensorarten durch den Verbund genutzt und ihre Nachteile mit dem Ziel der bestmöglichen Ortung relativiert oder gänzlich umgangen werden. Gegenüber der Nutzung einer einzelnen Sensorkategorie steht ein unter Umständen deutlich erhöhter Implementierungs- und Leistungsaufwand, da zunächst eine geeignete Methodik für die Fusion gefunden und das gesteigerte Datenaufkommen verarbeitet werden muss.

Ruser und León [RPL07] teilen die Integration von Sensoren dabei in die drei Kategorien „konkurrierende Integration“, „komplementäre Integration“ und „kooperative Integration“ auf, ersichtlich in Abbildung 3.8.

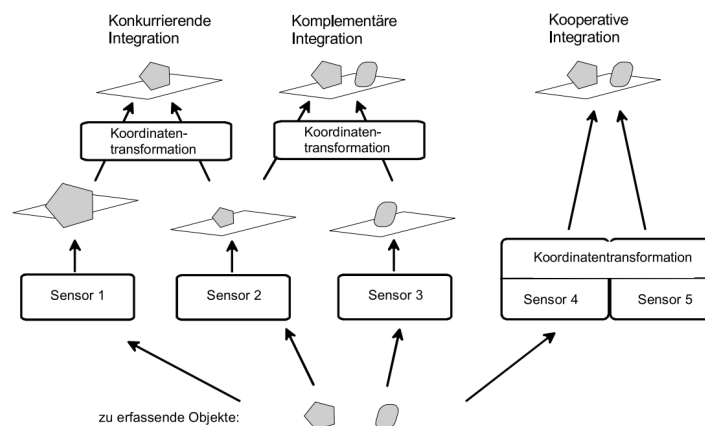


Abbildung 3.8: Aufteilung der Arten der Sensorintegration nach Ruser und León [RPL07, S. 6]

Hierbei entspricht die konkurrierende Einteilung der Integration von Daten „gleichartiger Sensoren mit gleicher Nutzinformation mit dem Ziel, Unsicherheiten zu reduzieren“. Die Komplementäre Integration bezeichnet hingegen „unterschiedlich[e] Nutzinformation mit dem Ziel, Informationslücken zu vervollständigen“. Als kooperative Integration wird schließlich die verteilte Nutzinformation und die damit einhergehende Auswertung sämtlicher Messdaten bezeichnet, mit der erst eine vollständige Interpretation des Ergebnisses möglich wird.

Die eingesetzte Sensor-Fusion für die absolute Ortung hat zum Ziel, Mehrdeutigkeiten und Unsicherheiten zu reduzieren und basiert auf der Fusion unterschiedlicher Sensorarten und damit auch unterschiedlicher Nutzinformationen. Sie entspricht damit der komplementären Integration nach Ruser und León, da die Messwerte aller Sensoren zusammengelegt werden

und eine möglichst eindeutige Position ergeben, die nicht interpretiert werden muss.

Je nach Art der Implementierung kann eine Einteilung der Fusion mit relativer Ortung (siehe Kapitel 3.2) ebenfalls schwierig sein. Da eine reine Mittelung der Position stattfinden könnte, würde es sich um eine konkurrierende Integration handeln. Eine im Hinblick auf die Genauigkeit und Zuverlässigkeit der Ortung sinnvollere Fusion wäre allerdings die kooperative Integration, sodass die Position als Interpretation von relativer und absoluter Ortung angenommen wird. Diese Unsicherheit ist ein Grund für das Fokussieren des Projekts auf die absolute Ortung und das Verlegen einer sinnvoll implementierten relativen Ortung in den Ausblick.

Das eigentliche Fusionieren der Sensoren beim Fingerprinting orientiert sich im Wesentlichen am Nearest Neighbor Verfahren des RADAR Systems, insofern als dass auch in IndoorGPS die Vektor-Distanzen zwischen der aktuellen Messung und sämtlichen gespeicherten Messungen berechnet und der Messpunkt mit dem geringsten Abstand als Position angenommen wird. Erschwerend kommt allerdings hinzu, dass, wie in Kapitel 3.1.2 beschrieben, RADAR wie die meisten absoluten Fingerprinting-Verfahren lediglich WiFi als Grundlage zur Ortung nutzt.

Um nun nicht nur einen, sondern potenziell beliebig viele Sensoren bei der Vektor-Distanz beachten zu können, werden deshalb die Vektoren um jeweils eine Dimension für simple Sensoren mit einzelnen Signalstärken (Magnetometer, Mobilfunk, ...), beziehungsweise  $n$  Dimensionen für komplexere Sensoren mit Listen von Signalstärken (WiFi, Bluetooth, ...) erweitert. Hieraus ergeben sich jedoch Gewichtungprobleme, die in Abschnitt 3.4 weiter behandelt werden.

Schaubild 3.9 stellt die Vorgehensweise der Erweiterung und Fusion dar.

Da Sensoren mit Ergebnislisten an unterschiedlichen Orten häufig unterschiedliche Listen zurückgeben - ein WiFi-Sensor kann an einem Ort andere Netze entdecken als an einem anderen Ort, ein Bluetooth-Sensor andere Geräte und so weiter - wird jede Dimension des Vektors mit einer ID versehen, um die korrekte Zuordnung gewährleisten zu können. Bei simplen Sensoren entspricht diese ID einem beschreibenden Namen des Sensors, bei komplexen Sensoren wird jedem Listeneintrag die ID zugeordnet. Für WiFi-Netze eignet sich hier etwa die BSSID, für sichtbare Bluetooth-Geräte die MAC-Adresse des Geräts und so fort. Ist ein Wert in einem der Vektoren nicht enthalten, wird er mit der Stärke 0 angenommen.

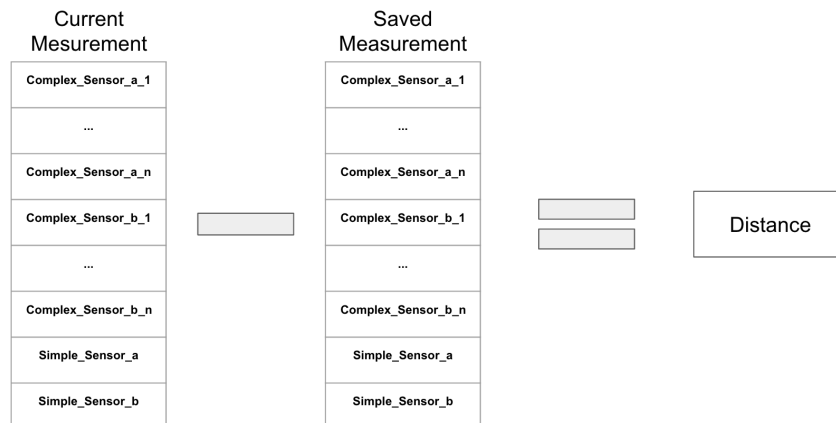


Abbildung 3.9: Erweiterung und Verrechnung der Signal-Vektoren bei der Sensor-Fusion [Eigene Darstellung]

Die Ähnlichkeit zweier Vektoren lässt sich auf unterschiedliche Weise feststellen. Zu den naheliegendsten simplen Methoden gehört dabei, den räumlichen Abstand zwischen beiden Vektoren anhand der euklidischen Distanz zu berechnen:

$$d_{Euclidean}(x_i, x_j) = \sqrt{\sum_{n=0}^N (x_{i,n} - x_{j,n})^2} \quad (3.3)$$

[Rah08, S. 3]

Anstatt die direkte Strecke zwischen zwei Vektoren zu bestimmen, lässt sich allerdings auch eine komponentenweise Differenz ermitteln. Die Manhattan-Distanz gibt die Summe der absoluten Differenzen zweier Vektoren an:

$$d_{Manhattan}(x_i, x_j) = \sum_{n=0}^N |x_{i,n} - x_{j,n}| \quad (3.4)$$

[Rah08, S. 4]

Vorstellen lässt sich der Unterschied beider Verfahren anhand der Route, die Taxifahrer im schachbrettartig aufgebauten Manhattan nehmen müssen<sup>6</sup>, weshalb die Berechnung auch

<sup>6</sup><http://mathworld.wolfram.com/TaxicabMetric.html>

Taxicab-Metrik oder City-Block-Distanz genannt wird, wie in Abbildung 3.10 erkennbar (hierbei spiegelt die grüne Linie den euklidischen Abstand, alle weiteren Darstellungen der Manhattan-Distanz wieder).

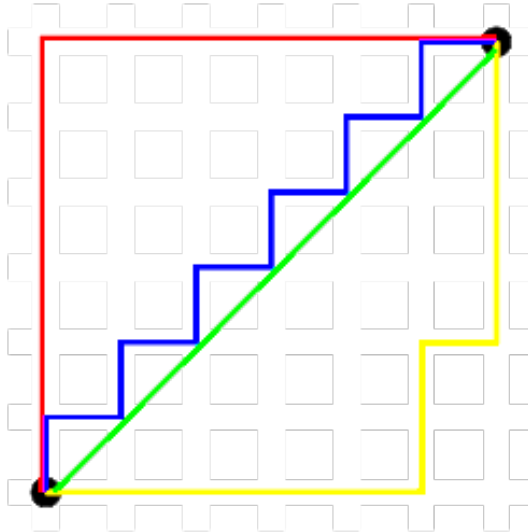


Abbildung 3.10: Unterschied zwischen euklidischer und Manhattan-Distanz<sup>7</sup>

In der Grafik wird ersichtlich, dass die euklidische Distanz zweier Vektoren immer höchstens so groß ist wie ihre Manhattan-Distanz, da stets der direkte Abstand berechnet wird. Um beim Fingerprinting die Differenzen zwischen der aktuellen Messung und den gespeicherten Messungen zu maximieren und die Werte möglichst stark unterscheidbar zu gestalten, wird deshalb in IndoorGPS die Manhattan-Distanz genutzt.

### Normalisierung und Sensorgewichtung

Beim Vergleich von Messwerten innerhalb der Sensorfusion entsteht leicht ein Ungleichgewicht zwischen den Sensoren, wie bereits im Hauptprojekt [Bar16b] erörtert. Da pro Zeitschritt beispielsweise beim WiFi- und Bluetooth-Sensor jeweils Listen mit Einträgen betrachtet werden, während dies etwa beim Magnetometer einzelne Werte sind, wird durch simples Summieren der Einträge ein  $n$  zu 1-Verhältnis geschaffen. Am Beispiel WiFi/Magnetometer ergäbe dies die

---

<sup>7</sup>[https://commons.wikimedia.org/wiki/File:Manhattan\\_distance.svg](https://commons.wikimedia.org/wiki/File:Manhattan_distance.svg), Abruf: 11.11.16

in 3.5, bzw. 3.6 gezeigten Differenzen zum Nullpunkt.

$$\begin{aligned}
 & WiFi \\
 Diff_{WiFi} &= \sum_{n=0}^N Signal\ Strength_{WiFi\ n} \quad (3.5)
 \end{aligned}$$

$$\begin{aligned}
 & Magnetometer \\
 Diff_{Magnet} &= Signal\ Strength_{Magnet} \quad (3.6)
 \end{aligned}$$

Das Ergebnis einer solchen Rechnung wäre eine im Vergleich äußerst geringe Gewichtung des Magnetometers in der Differenzberechnung zur Positionsbestimmung, von der physikalischen Unsinnigkeit ganz abgesehen.

Es gilt somit, für jedes Sensorergebnis einen Wert zu berechnen, der mit allen weiteren Messungen vergleichbar ist. Die Ergebnisse müssen also normalisiert werden. Hierfür muss für jeden Sensor der Bereich der gemessenen Werte, also der jeweils größte Ausreißer aller Messungen mit dieser Sensorart, ermittelt werden. Hiernach wird im Vergleich in der Online-Phase die Differenz eines Datenpaares durch diesen Wert dividiert, was zu Werten zwischen 0 und 1 führt. Da dieser Wert die Differenz angibt, ist noch eine Invertierung notwendig. Wird die Differenz von 1 subtrahiert, ist das Ergebnis die prozentuale Ähnlichkeit eines Paares, ersichtlich in Formel 3.7.

$$Diff_{Normalized} = 1 - \frac{\sum_{n=0}^N Diff_n}{N \cdot Diff_{max}} \quad (3.7)$$

Durch die Normalisierung der Sensorarten jeweils auf Ähnlichkeiten zwischen 0 und 100% ergeben sich gleich mehrere Vorteile. So wird nicht nur die gleiche Gewichtung für jeden Sensor erreicht; es kann weiterhin jeder Sensor leicht mit einer neuen Gewichtung versehen werden, ganz gleich ob dies zu Beginn der Messungen fix oder zur Laufzeit dynamisch geschehen soll, um beispielsweise das Vertrauen in die Ergebnisse eines Sensors ausdrücken zu können.

Auch die Deaktivierung einzelner Sensoren wird durch eine Gewichtung von 0 ermöglicht. Zuletzt ergibt sich eine gute Lesbarkeit der Positionswerte, die sich besonders während der Entwicklung und für die Vergleichbarkeit als sinnvoll erwies.

Formel 3.8 zeigt darüber hinaus die Durchschnittsberechnung der gewichteten Differenzen aller Sensoren. Hierbei wird jedem Sensor ein fester Faktor zugewiesen und das Ergebnis anschließend durch die Gesamtgewichtung geteilt. Eine feste Gewichtung von 1 entspricht damit dem arithmetischen Mittel.

$$Diff_{FusedAndWeighted} = \sum_{n=1}^N \frac{Weight_n \cdot Diff_{Normalized}}{\sum_{i=1}^I Weight_i} \quad (3.8)$$

In IndoorGPS wird neben der festen Gewichtung für jeden Sensor als Optimierung eine Gewichtung anhand der Größe des Wertebereichs der Sensoren vorgenommen. Ziel ist das Testen der Hypothese, ob die Genauigkeit durch das Abschwächen solcher Sensoren erhöht werden kann, die kaum Signaturen aufweisen und damit wenig zur Unterscheidung der Positionen beitragen können. Näheres zu der Optimierung findet sich in Kapitel 4.2.5.

## 3.5 Filterung

Das Beseitigen von Sprüngen in den Messergebnissen ist Aufgabe der Filter. Prinzipbedingt ist kein Sensor hundertprozentig genau, es treten also in jedem Fall Messungenauigkeiten auf, die das Ergebnis verfälschen. Bei der Fusion von Sensoren steigt die Wahrscheinlichkeit von Sprüngen darüber hinaus noch an, da die Messungen mehrerer Sensoren sich gegenseitig widersprechen oder ihre Fehler sich akkumulieren können. Besonders in diesem Kontext ist daher der Einsatz von Filtern für eine zuverlässige Ortung empfehlenswert.

Ein großer Teil der in der Positionierung verwendeten Filter lässt sich in deterministische und probabilistische Verfahren einteilen. Probabilistische Filter beziehen vorhergehende Messungen in die Filterung mit ein, indem auf der Basis eines Bewegungsmodells oder mit Hilfe der Signalverteilungen Schätzungen über folgende Positionen abgegeben und durch bisherige

Messungen korrigiert werden.

Die Verfahren sind mit der aktuellen Fassung von IndoorGPS nicht umsetzbar, da als Eingrenzung für diese Arbeit der Fokus rein auf eine absolute Ortung und deterministisches Fingerprinting gelegt wird. Die Fingerprints sind in diesem Fall jedoch physikalisch gesehen voneinander nicht zwingend abhängig, folgen also keinem vorhersagbaren Bewegungsmodell, weshalb für die Nutzung probabilistischer Filter die ausgegrenzte relative Ortung hinzugezogen werden müsste. Probabilistische Filter gelten grundsätzlich als etwas genauer als ihre deterministischen Gegenstücke (vgl. [HPALP09]), da sie durch die temporale Nutzung der Daten mehr Informationen verarbeiten. Einige Verfahren werden daher für eine mögliche Weiterentwicklung des Systems in Ausblick gestellt und aus diesem Grund im aktuellen Kapitel kurz vorgestellt.

#### 3.5.1 Nearest Neighbor

Um deterministische Ergebnisse zu filtern, haben sich das Nearest Neighbor (NN) Verfahren und ihm verwandte Algorithmen etabliert (vgl. etwa [BP00]). Das Verfahren setzt dabei genau das Vorgehen um, das intuitiv beim Vektor-Vergleich genutzt wird: Zuerst wird für jeden gespeicherten Messvektor die Ähnlichkeit zur aktuellen Messung berechnet. Der Vektor der gespeicherten Messergebnisse mit dem geringsten Abstand zur aktuellen Messung wird daraufhin als Position angenommen.

Eine der ersten und bekanntesten Arbeiten im Feld der Ortung in Gebäuden, in denen das Nearest Neighbor Verfahren genutzt wurde, ist das RADAR System (vgl. [BP00]). Allerdings stellten die Autoren fest, dass kein triftiger Grund dafür bestehe, nur den ähnlichsten Vektor als Position anzunehmen und alle nächstähnlichen Vektoren einfach zu verwerfen. Auch nahmen sie an, dass die weiteren Vektoren mit hoher Wahrscheinlichkeit Fehler in eine andere Richtung aufwiesen als der ähnlichste Vektor. Während also der ähnlichste Vektor mit einer Komponente in die negative Richtung vom aktuellen Messwert abdriftet, könnte sich ein weiterer ähnlicher Vektor in die positive Richtung vom Ergebnis entfernen.

Das Kombinieren mehrerer Nachbarn zu einer ihrem arithmetischen Mittel entsprechenden Position, k-Nearest Neighbors, kurz „KNN“, genannt, führte in RADAR zwar zu einer Steigerung der Genauigkeit; allerdings ebenso zu Artefakten, da eine Messähnlichkeit nicht zwingend einer räumlichen Nähe entspricht. Das bedeutet, dass zwei sich stark ähnelnde Messungen im



schlechtesten Fall an gegenüberliegenden Orten der Karte liegen können. Aus diesem Grund kann KNN die Genauigkeit unter Umständen auch verschlechtern.

Die Größe von  $K$ , also die Anzahl der ins Ergebnis einfließenden Nachbarn, zu variieren, führt zu unterschiedlichen Ergebnissen. Allgemein lässt sich sagen, dass sehr niedrige  $K$ s Sprünge nicht effektiv filtern, höhere  $K$ s hingegen das Messergebnis aus oben genanntem Grund aufgrund von Verzerrungen durch immer unpassendere Messpunkten eher verschlechtern. Das Verhalten des Werts auf das Ergebnis lässt sich der Grafik 3.11 entnehmen, wobei sich die Werte 3 und 4 als sinnvoller Kompromiss zwischen Rechenaufwand und Genauigkeit herausgestellt haben.




Abbildung 3.11: Auswirkung von  $K$  auf das Ergebnis [MJC<sup>+</sup>15, S. 5739]

Anstatt jeden Nachbarn zu gleichem Anteil in die Positionsrechnung einfließen zu lassen und somit das arithmetische Mittel zu berechnen, kann die Gewichtung auch optimiert werden, um zum Beispiel den Anteil weit entfernter Nachbarn zu verringern und das Ergebnis zu verbessern. Dieser Ansatz wird Weighted  $k$ -Nearest Neighbors (WKNN) genannt. Ein guter Anhaltspunkt für die Bestimmung der Gewichtung ist es, die inverse Entfernung als Faktor zu

nutzen, sodass die Gewichtung sinkt, je weiter der Nachbar von der aktuellen Position entfernt ist:

$$w_i = \frac{1}{\text{dist}_{phys_i}} \frac{1}{\sum_{i=1}^K \frac{1}{\text{dist}_{phys_i}}} \quad (3.9)$$

[LGL12, S. 59]

Hieraus ergibt sich schließlich die Position, indem das Mittel aller Koordinaten mit der jeweiligen Gewichtung multipliziert wird:

$$pos_{x,y} = \sum_{i=1}^K w_{i,x,y} pos_{x,y}^i \quad (3.10)$$

[LGL12, S. 59]

Wie sich anhand von 3.10 erkennen lässt, sind sowohl NN als auch KNN Spezialfälle des WKNN, indem als Gewichtung (entspricht KNN), beziehungsweise zusätzlich als K (entspricht NN) jeweils 1 angenommen wird.

Neben den beschriebenen grundlegenden Nearest Neighbor Ausprägungen gibt es noch weitere Verbesserungen des Vorgehens. Eines ist das Enhanced Weighted k-Nearest Neighbors [SLLK12], bei dem K nicht als fixer Wert gesehen, sondern während der Ortung angepasst wird. Hierbei nutzten Shin et al in engen Korridoren mit wenigen Messpunkten ein niedrigeres K als in weitläufigeren Räumen und verbesserten so noch einmal leicht die Genauigkeit gegenüber dem bekannten WKNN. Trotz nur geringer Verbesserungen und höherem Aufwand gegenüber WKNN kann das Verfahren daher für eine Weiterentwicklung von IndoorGPS ins Auge gefasst

---

<sup>8</sup>Die ursprüngliche Formel der Quelle enthält fälschlicherweise erneut die Mittelung durch die Division mit K. Diese Mittelung ist allerdings bereits in den Gewichtungen aus 3.9 enthalten und wurde daher weggelassen (vgl. auch [LCJ<sup>+</sup>15, S. 31247]).



### 3.5.2 Kalman-Filter

Das Kalman-Filter beschreibt als probabilistisches Filter einen rekursiven Filterungsprozess, bei dem abwechselnd die Prädiktion eines Ergebnisses auf der Basis vorhergehender Messungen mit der aktuellen Messung verrechnet und anschließend von dieser wieder korrigiert wird. Das Vorgehen lässt sich in dem Ablaufdiagramm 3.13 ablesen. Im Alltag lässt sich das Kalman-Filter bei der Fahrt mit dem Auto in einen Tunnel wiederfinden, bei der trotz eines Ausfalls des GPS-Signals weiterhin eine ungefähre Position ausgegeben und die Navigation im Tunnel - wenn auch ungenau - fortgesetzt werden kann.

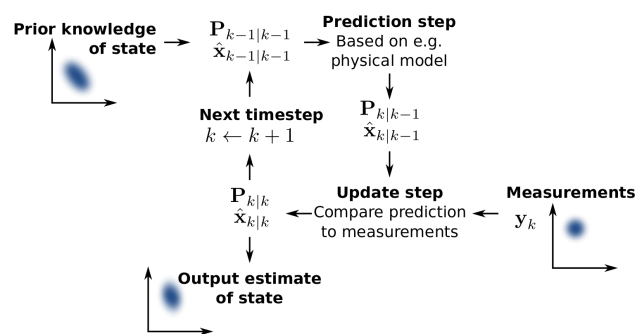


Abbildung 3.13: Schritte des Kalman-Filters<sup>9</sup>

Im einfachsten, eindimensionalen Fall lässt sich mit Hilfe des Kalman-Filters der Einfluss einer genauen Messung stärker gewichten als der einer weniger genauen. Die Genauigkeit kann dabei bestimmt werden, indem der Mittelwert der Messungen  $\mu$  und die durchschnittliche Abweichung von diesem Mittelwert in Form der Varianz  $\sigma^2$  berechnet werden (vgl. [Gut00]).

Bildet man die Messung gaußverteilt ab, lässt sich diese durch das Kalman-Filter mit einer weiteren Gauß-Kurve verrechnen, um eine optimierte Verteilung zu erhalten. In Abbildung 3.14 ist dieses Vorgehen anhand der blauen Kurve der Messung zu erkennen, die mit der roten Kurve der Schätzung zu der grünen, optimierten Verteilung verrechnet wird. Die optimierte Verteilung liegt dabei deutlich näher an der genaueren Messkurve, da diese im gezeigten Schritt die sicherere Quelle darstellt. Erkennbar ist dies an der spitzeren Kurvenform und damit der niedrigeren Varianz.

<sup>9</sup>[https://commons.wikimedia.org/wiki/File:Basic\\_concept\\_of\\_Kalman\\_filtering.svg](https://commons.wikimedia.org/wiki/File:Basic_concept_of_Kalman_filtering.svg), Abruf: 15.01.17

<sup>10</sup><http://www.roomaps.com/de/technology>, Abruf: 15.01.17




Abbildung 3.14: Funktionsweise des Kalman-Filters<sup>10</sup>

Die Verrechnung findet statt, indem für Prädiktion und Messung gemeinsame Varianzen und Mittelwerte ermittelt werden. Im einfachsten Fall mit einer Dimension und ohne Korrektur entspricht die neue Varianz im ersten Schritt des Filters

$$\sigma_{neu}^2 = \frac{1}{\frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2}} \quad (3.11)$$

(Vgl. [Sch13, S. 5])

und der neue Mittelwert

$$\mu_{neu} = \frac{\sigma_2^2 \mu_1 + \sigma_1^2 \mu_2}{\sigma_1^2 + \sigma_2^2} \quad (3.12)$$

(Vgl. [RL00, S. 7])

Einen Zeitschritt später wird aufgrund der neuen Messung das Ergebnis korrigiert:

$$X(t_2) = X(t_1) + K(t_2)(z_2 - X(t_1)) \quad (3.13)$$

(Vgl. ebd. S. 8)

mit

$$K(t_2) = \frac{\sigma_{z_1}^2}{\sigma_{z_1}^2 + \sigma_{z_2}^2} \quad (3.14)$$

$z_1$  und  $z_2$  sind hierbei die Positionen zum Zeitpunkt  $t_1$ , bzw.  $t_2$ .

$K(t_2)$  entspricht der Gewichtung, die sich aus der Differenz zwischen Schätzung und Messung ergibt. Das Konzept der Gewichtung, die mit Hilfe der Varianzen errechnet wird, fließt in die statische Optimierung (siehe Kapitel 4.2.5) von IndoorGPS ein, um den Einfluss ungenauerer Sensoren zu reduzieren. Mit der Gewichtung kann somit auch der Ausfall von Sensoren ausgeglichen werden, indem sie für diesen nulliert wird und auf die übrigen Sensoren zurückgegriffen sowie auf ihrer Basis eine Schätzung abgegeben wird.

Das Kalman-Filter wird normalerweise für mehrdimensionale Systeme und häufig in Form komplexerer Erweiterungen genutzt, mit denen sich nichtlineare Gleichungssysteme lösen lassen (das in Kapitel 3.3 erwähnte „Fingerprint Extended Kalman Filter“ stellt eine dieser Erweiterungen dar). Eine einfache Erklärung zur tiefergehenden Auseinandersetzung mit dem Thema lässt sich etwa im Vorlesungsmaterial [Pos16] der HTW-Dresden finden.

#### 3.5.3 Partikel-Filter

Das Partikel-Filter basiert auf der Vorgehensweise, mehrere Hypothesen aufzustellen und nur die wahrscheinlichsten von ihnen weiter zu verfolgen. Im Kontext der Ortung bedeutet dies, dass um die zuletzt bekannte Position herum gewichtete, zufällige Schätzungen, die namensgebenden Partikel, abgegeben und als mögliche Orte angenommen werden. Diejenigen Partikel mit der höchsten Wahrscheinlichkeit werden jeweils als neue aktuelle Position gesetzt und um sie herum erneut Schätzungen abgegeben.

Das Abgeben und Reduzieren von Schätzungen wird nun wiederholt und damit eine genauere, sprungrärmere Ortung ermöglicht. Die Schritte Hypothesen Erstellen und Hypothesen Reduzieren sowie die hierdurch erhöhte Genauigkeit sind in der Grafik 3.15 von links nach

rechts erkennbar.




Abbildung 3.15: Abfolge der Verfeinerung des Partikel-Filters<sup>11</sup>

Das Filter besteht also aus drei sich wiederholenden Schritten (vgl. [Har13]):

- Update - Partikel werden, basierend auf der bisherigen Bewegung, um die aktuelle Position herum abgegeben.
- Correct - Jedem Partikel wird eine Gewichtung zugewiesen, deren grundlegende Höhe der Nähe der Schätzung zur Folgeposition des Bewegungsmodells entspricht.
- Resample - Neue Partikel werden der aktuellen Gewichtung entsprechend verteilt, um eine hohe Partikeldichte an Orten mit höherer Wahrscheinlichkeit zu erreichen.

Die Hypothesen des Partikel-Filters können dabei mit komplexen Bedingungen versehen werden (vgl. ebd.), zum Beispiel dass Schätzungen nicht in unbegehbarem Gelände oder nicht außerhalb eines festgelegten Radius' abgegeben werden. Liu et al. [LDRZ14] etwa nutzten semantische Karten, also mit zusätzlichen Informationen wie Treppen oder unbegehbare Orte versehene Grundrisse, um die Gewichtung der betroffenen Partikel zu verringern. Hierdurch wurde zwar die Genauigkeit der Ortung erhöht, allerdings gleichzeitig die einfache Skalierbarkeit solcher Systeme erschwert, da die Karten erst mit den entsprechenden Informationen versehen werden müssen. Liu et al. begegneten diesem Problem mit einem Crowd-Sourcing-Ansatz, um die Datenbank mit diesen Informationen aktuell zu halten und die Daten zu optimieren.

Partikel-Filter erreichen im Allgemeinen bessere Ergebnisse als Kalman-Filter, neben Vorteilen wie der Nutzung semantischer Karten auch weil nicht nur eine, sondern sehr viele

---

<sup>11</sup><http://www.roomaps.com/de/technology>, Abruf: 15.01.17

Hypothesen verfolgt werden und sie besser für die komplexeren Bewegungsmodelle der Nutzer geeignet sind (vgl. etwa [HC16]). Sie benötigen für eine hohe Genauigkeit jedoch eine hohe Partikeldichte, häufig im Bereich von Hunderten (vgl. [Har13], [NRALP13]), oder mehr Partikeln, damit genügend Partikel an wahrscheinlicheren Positionen vorhanden sind. Das parallele Verfolgen vieler Hypothesen schlägt sich hierbei direkt in der benötigten Rechenlast sowie dem Speicher- und Energieverbrauch nieder, weshalb das Partikel-Filter als einzige Filterart, trotz ihrer im Vergleich einfacher zu implementierenden Natur, in einer mobilen Anwendung ohne gesonderte Server-Infrastruktur selten sinnvoll ist (vgl. [LCJ<sup>+</sup>15]). Auch sind Partikel-Filter für die Positionierung nicht unbedingt notwendig und werden aus Leistungsgründen oft vermieden, wenn das Kalman-Filter bereits eine ausreichende Qualität gewährleisten kann (vgl. [HC16]). Eine Ausnahme bilden hybride Systeme wie SmartSLAM [FH13], die zwischen Kalman- und Partikel-Filter wechseln, um bei Bedarf eine höhere Filterqualität mit niedrigeren Leistungsanforderungen kombinieren.

Eine weitere, technisch simple Möglichkeit, die Leistungsanforderungen zu senken, ist das Clustern, das als Abschluss dieses Kapitels im Folgenden vorgestellt wird.

## 3.6 Clustering

Als Clustering wird das Zusammenfassen von Objekten anhand von Ähnlichkeitsmerkmalen in Gruppen bezeichnet. Oft besteht das Ziel neben dem Erkennen von Ausreißern, also jenen Objekten, die sich keinem Cluster zuordnen lassen, darin, die zu durchsuchende Wertemenge zu reduzieren, indem diese auf einzelne Gruppen beschränkt wird.

Das Verfahren, Modelle zu untersuchen, geeignete Cluster zu finden und zuzuordnen sowie die anschließende Interpretation der Erkenntnisse wird Clusteranalyse genannt. Es besteht aus den folgenden Schritten (vgl. [JMF99]), die auch wiederholt stattfinden können:

1. Muster-Erkennung
2. Ähnlichkeitsmaß-Bestimmung
3. Gruppierung
4. (Optional) Datenabstraktion



**Muster-Erkennung:** Im ersten Schritt werden die Eigenschaften festgelegt, nach denen die Objekte geclustert werden sollen. Auch das Clusteringverfahren und die Anzahl der Cluster oder, je nach Vorgehensweise, die maximale Anzahl der Objekte pro Cluster werden hierin definiert.

**Ähnlichkeitsmaß-Bestimmung:** Um Objekte einem Cluster zuzuordnen zu können, muss ihre Ähnlichkeit zueinander ermittelt werden. Dies geschieht anhand von Ähnlichkeits-, beziehungsweise Distanzmaßen, wie sie auch in Kapitel 3.4 beschrieben werden.

**Gruppierung:** Das eigentliche Clustern der Objekte in Gruppen sich ähnelnder Nachbarn geschieht im dritten Schritt. Die Bestimmung des Clusters kann hierbei scharf oder unscharf geschehen. Bei der scharfen Bestimmung wird jedes Objekt fest einer Gruppe zugeordnet; unscharf bedeutet hingegen, dass dem Objekt ein variabler Anteil eines jeden Clusters zugewiesen wird, der sich im Laufe des Verfahrens verschieben und damit die Zuordnung ändern kann.

**Datenabstraktion:** Optional können nach dem Clustern Schlüsse gezogen sowie das Ergebnis interpretiert und weiterverwendet werden. Ist das Ergebnis nicht zufriedenstellend, wird spätestens zu diesem Zeitpunkt das Vorgehen wiederholt und ein anderes Clusteringverfahren gewählt. Darstellung 3.16 zeigt die unterschiedlichen Ergebnisse zweier Verfahren am Beispiel eines Musterdatensatzes, wobei das Verfahren k-Means die ursprünglichen Cluster nicht ausreichend zuordnen kann. Die Entscheidung, ob das Ergebnis den Anforderungen entspricht, ist hierbei oft nicht leicht allgemeingültig treffbar.

Die Zurdnung von Objekten zu Clustern geschieht entweder agglomerativ oder divisiv (vgl. [Vos11, S. 48]). Agglomerative Verfahren stellen jedes Objekt anfangs als Cluster dar und fügen diese solange zusammen, beispielsweise bis die gewünschte Anzahl an Clustern erreicht ist. Divisive Verfahren arbeiten dazu invers, indem sie ein einziges, alle Elemente enthaltendes Cluster aufteilen. Abbruchkriterien können unter anderem auch eine maximale Laufzeit, eine festgelegte Anzahl an Objekten pro Cluster oder das Erreichen des gewünschten Ergebnisses sein.

Agglomerative Verfahren benötigen einen Fusionierungsalgorithmus, der den Abstand zweier Cluster zueinander analog zur Entfernungsbestimmung zwischen zwei Objekten mit-

---

<sup>12</sup>[https://de.wikipedia.org/wiki/Cluster\\_\(Datenanalyse\)](https://de.wikipedia.org/wiki/Cluster_(Datenanalyse)), Abruf: 07.01.17

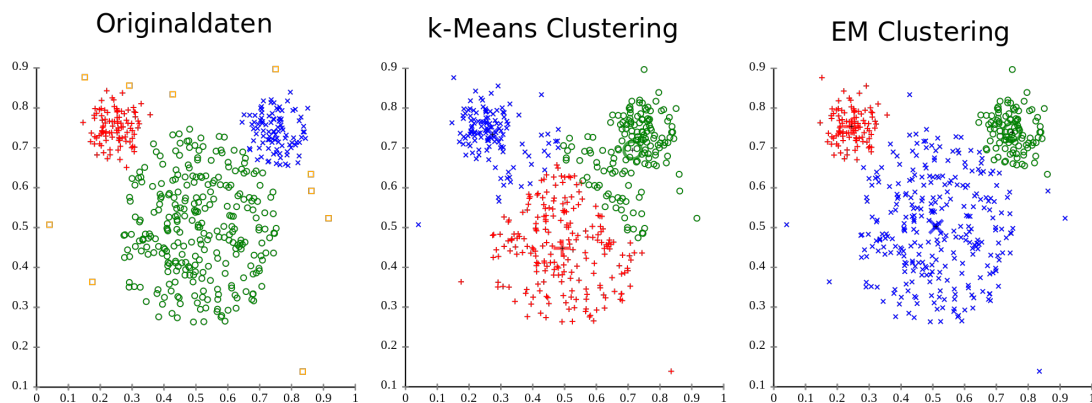


Abbildung 3.16: Ergebnisse unterschiedlicher Clusteringverfahren [Titel entfernt]<sup>12</sup>

tels Distanzmaß nutzt, um Cluster miteinander zu verschmelzen. Bekannte agglomerative Verfahren sind die Linkage-Clustering Algorithmen (vgl. [MC12]). Diese arbeiten mit dem minimalen (Single-Linkage- / Nearest Neighbour-Clustering), dem mittleren (Average-Linking-Clustering), beziehungsweise dem maximalen (Complete-Linkage-Clustering) Abstand jedes Clusters zu allen übrigen Clustern. Beim Single-Linkage-Clustering werden solche Cluster zusammengefügt, die den kleinsten Abstand zueinander aufweisen. Analog arbeiten die weiteren Linkage-Verfahren.

Neben der sehr hohen Laufzeit haben naive Linkage-Clustering Algorithmen jeweils weitere, teils schwerwiegende Nachteile wie der Neigung zur Kettenbildung des Single-Linkage-Clusterings oder der Tendenz zur Bildung kleiner Gruppen des Complete-Linkage-Clusterings, weshalb im Laufe der Jahre aus den Verfahren viele weitere Optimierungen und Weiterentwicklungen entstanden sind. Eine Auswahl dieser Weiterentwicklungen findet sich etwa in der Übersicht von Murtagh und Contreras [MC12].

Bekannte divisive Verfahren sind der k-Means-Algorithmus als scharf zuordnendes Verfahren (vgl. [Mac67]) und das diesem ähnelnde, probabilistische und unscharf zuordnende Expectation-Maximization (vgl. [DLR77]), kurz „EM“. Das simplere k-Means arbeitet nach dem Prinzip, k zufällige Clusterschwerpunkte anzunehmen, denen jeweils die Objekte mit minimalem Abstand zugeordnet werden. Es folgt die Verschiebung der Schwerpunkte, mit der Bedingung minimaler quadrierter Abstände zueinander und die Wiederholung des Verfahrens bis das Abbruchkriterium erfüllt ist. Auch k-Means wurde im Laufe der Zeit weiterentwickelt.

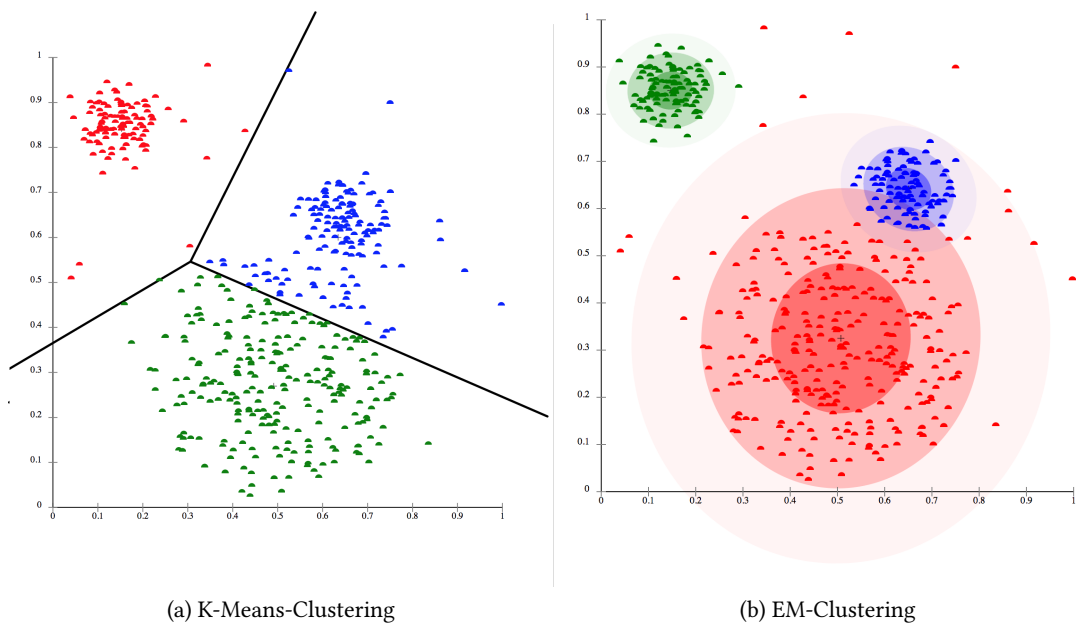


Abbildung 3.17: Funktionsweise K-Means- und EM-Clustering<sup>13</sup>

So liegt etwa der Fokus von k-Means++ auf der besseren initialen Verteilung der Schwerpunkte (vgl. [AV07]), Charles konzentrierte sich hingegen auf die Laufzeitreduzierung (vgl. [Elk03]) und so fort.

Der EM-Algorithmus wiederum arbeitet mit der, häufig nicht bekannten, Wahrscheinlichkeitsverteilung der enthaltenen Objekte und iteriert die beiden namensgebenden Schritte Expectation und Maximization, um sich der Verteilung anzunähern. Zuerst werden zufällige Mittelwerte als Clusterschwerpunkte gewählt, denen die Objekte anhand der minimalen Varianz zugeordnet werden. Anschließend werden die Schwerpunkte neu verteilt, sodass der Erwartungswert der Cluster jeweils maximiert wird. Die Schritte werden solange wiederholt, bis die Verschiebung der Schwerpunkte unter einen festgelegten Schwellwert fällt (vgl. etwa [Voi09]).

Grafik 3.17 zeigt das Vorgehen beider Verfahren und die scharfe, beziehungsweise unscharfe Einteilung, gut an den Überschneidungen in Diagramm b erkennbar. Je nach Leistungsanforderung und gewünschter Genauigkeit kann eines der vorgestellten Clustering-Verfahren

<sup>13</sup>[https://commons.wikimedia.org/wiki/Cluster\\_analysis](https://commons.wikimedia.org/wiki/Cluster_analysis), Abruf: 07.01.17

gewählt werden, was in der Indoor-Positionierung besonders bei umfangreichen Datenmengen und den im Vergleich zum deterministischen Vorgehen anspruchsvolleren probabilistischen Ansätzen sinnvoll ist. Da sich die in IndoorGPS genutzte Datenmenge im Rahmen der Versuche (siehe Kapitel 4.4) als gering genug herausstellte, wird zum aktuellen Zeitpunkt noch keine Clusterung benötigt. Sie sollte jedoch für Weiterentwicklungen des Projekts erneut evaluiert werden.

## 4 IndoorGPS

Im Praxisteil dieser Arbeit werden die theoretischen Grundlagen auf ihre Realisierbarkeit hin untersucht und es wird geprüft, inwiefern sich die ausgesuchten Verfahren bereits für eine Positionierung eignen. Die Erkenntnisse dieses Kapitels bilden damit eine begründete Ausgangssituation für den weiteren Ausblick.

Um hierüber eine Aussage treffen und die Theorie testen zu können, wurde mit IndoorGPS eine Anwendung entwickelt und hierbei ein Verfahrenssatz implementiert, den es zu evaluieren gilt. IndoorGPS stellt dabei eine Vergleichsplattform mit unterschiedlichen Kombinationen aus Sensoren und Lokalisierungsverfahren und dem Ziel einer robusten, raumweiten Lokalisierung dar, wie bereits im Hauptprojekt [Bar16b] eingeleitet. Im vorliegenden Kapitel werden zuerst die zugrundeliegende Architektur der App sowie der Benutzungsablauf vorgestellt. Anschließend wird durch die sogenannten Optimierungen (einzelne optionale Module zur Verbesserung der Positionierung) geführt und schließlich werden die Experimente und ihre Ergebnisse vorgestellt.

### 4.1 Architektur

Grob gesehen besteht IndoorGPS aus drei Modulen:

1. Sensoren: Enthält und verwaltet alle eingebundenen Sensoren sowie deren Messwerte.
2. Mapping: Zuständig für die Fingerprinting-Karte, auf denen fusionierte Messergebnisse verortet werden.
3. Optimierungen: Beinhaltet optionale Verbesserungen und Filter, die zwar nicht zur Ortung benötigt werden, diese aber potenziell verbessern (näher beschrieben in Kapitel 4.2).

Das Mapping stellt die zentrale Komponente der Anwendung dar. Im Rahmen dieses Moduls werden die fusionierten Messungen auf vom Nutzer angegebenen Pfaden verteilt und anschlie-

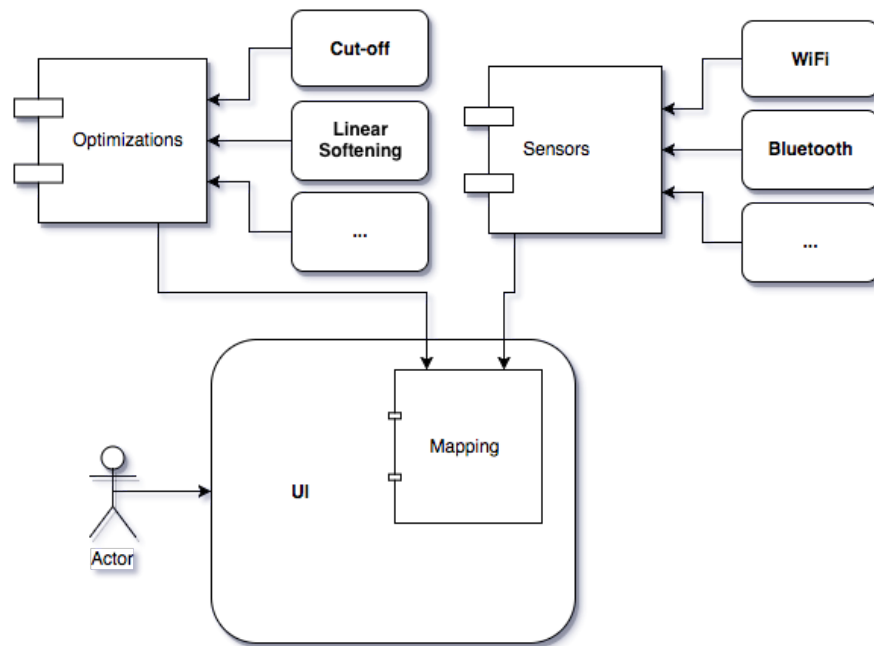


Abbildung 4.1: Komponenten von IndoorGPS [Aktualisierte Darstellung von [Bar16b, S. 4]]

ßend mit Live-Messungen des Smartphones verglichen, um die Position zu bestimmen. Zudem kann ein Grundriss verwaltet werden, auf dem die Messungen hinterlegt werden, oder es wird alternativ mit einem generischen Grundriss gearbeitet. Dies erlaubt, schnell Ergebnisse zu erlangen und Vergleiche zwischen unterschiedlichen Verfahrenskombinationen anzustellen.

Im Sensormodul sind alle Sensoren angebunden, werden initialisiert und anhand ihrer Lebenszyklen zur Laufzeit verwaltet. Die Pausierung der Sensoren sowie ihre Registrierung und Deregistrierung finden dort statt. Die eigentlichen Messergebnisse werden selbstständig von den Sensorinstanzen eingesammelt und innerhalb einer ständig aktualisierten FusedSensorData-Instanz der Anwendung zur Verfügung gestellt.

In IndoorGPS sind die folgenden Sensoren eingebunden:

- Bluetooth
- Magnetometer
- Mobilfunk
- Schrittzähler

- WiFi
- Mikrofon (eingehängt, aber aktuell ungenutzt)

Jeder Sensor liefert dabei eines von zwei möglichen Messergebnissen: Magnetometer und Mobilfunk liefern jeweils einzelne Messwerte pro Zeitschritt und werden daher als simple Sensoren gehandhabt. Bluetooth und WiFi erzeugen hingegen Messwertlisten und gelten damit als komplexe Sensoren. Die Unterscheidung ist, wie aus Kapitel 3.4 bekannt, für die Sensor-Fusion notwendig. Die eingesetzten Beacons stammen dabei von der Firma Kontakt.io<sup>1</sup>, deren Software Development Kit (SDK) auch zur Kommunikation eingesetzt wird.

### Implementierte Lokalisierungsverfahren

Um kurze Iterationen zu ermöglichen sowie eine solide Basis zu schaffen, auf der potenziell weitere Softwareiterationen aufgesetzt werden können und deren Positionierung weiterentwickelt werden kann, wurde die Komplexität der für diese Thesis implementierten Verfahren möglichst gering gehalten. Mit diesem Ansatz konnte vergleichsweise schnell getestet werden, ob die ermittelten Ansätze bereits ausreichende Ergebnisse ermöglichen. Es zeigte sich, dass dies nicht unter allen Bedingungen erreicht werden konnte, was in den folgenden Kapiteln beschrieben wird.

Als Hauptentscheidung fiel die Wahl auf die rein absolute Ortung und hierbei auf den deterministischen Fingerprinting-Ansatz. Das Fingerprinting hat sich in den bereits genannten Arbeiten als zuverlässige und genaue Alternative zur Trilateration bewiesen. Die Entscheidung gegen die relative Ortung reduzierte erheblich die Komplexität der Sensor-Fusion, da somit alle Messwerte auf einzelne oder mehrere Fließkommawerte heruntergebrochen werden konnten. Die relative Ortung hätte zu erheblichen Mehraufwänden geführt, da ein weiterer Fusionsschritt hätte eingeführt werden müssen oder die Fusion im Bewegungsmodell der Filter geschehen würde. Die Wahl der Filterung reduzierte sich aufgrund der Entscheidung gegen die relative Ortung mangels Bewegungsmodell allerdings auf deterministische Filter, was zum Weighted k-Nearest Neighbours Filtering mit einem k von 3 führte (siehe Kapitel 4.2.1).

Die implementierten Optimierungen werden im folgenden Abschnitt vorgestellt.

---

<sup>1</sup><https://kontakt.io>, Abruf: 18.01.2017

## 4.2 Optimierungen

Um Methoden und Ideen evaluieren zu können, die nicht zwingend für die Ortung benötigt werden oder teils Abweichungen von wissenschaftlich belegten Verfahren darstellen, wurde das Modul für Optimierungen implementiert. Die Vorstellung aller Optimierungen und das Beschreiben ihrer Funktionsweise ist Bestandteil der folgenden Abschnitte.

### 4.2.1 Filterung

Wie bereits erläutert wird das Filtern der Messergebnisse vom Weighted k-Nearest Neighbours Filtering mit einem k-Wert von drei durchgeführt. Die genaue Funktionsweise des Filters, inklusive der Berechnung der einzelnen Gewichtungen, lässt sich in Kapitel 3.5.1 nachlesen. Bei der Benutzung in der Anwendung ist das Ziel, den Einfluss auf die Sprungreduzierung und etwaige Einschränkungen, wie das Verschieben der Position in unbegehbare Bereiche, zu beobachten.

### 4.2.2 Messreduktion bei inaktivem Schrittzähler

Das Scannen nach neuen Messdaten hat einen teilweise erheblich gesteigerten Leistungsbedarf zur Folge, im Falle von WiFi-Scans ist der Bedarf des aktiven Sensors etwa rund 20 Mal so hoch wie der des inaktiven (vgl. [CSC<sup>+</sup>16]). Auch wenn der Energieverbrauch nicht den Fokus dieser Arbeit darstellt, empfiehlt es sich, den begrenzten Akku des Smartphones nicht durch unnötige Arbeit zu belasten und die Messungen nur dann durchzuführen, wenn sich der Nutzer bewegt. Dies kann durch das Zurückgreifen auf den Schrittzähler geschehen, indem die Messungen unterdrückt werden wenn eine gewisse Zeit kein Schritt und damit keine erhebliche Bewegung erkannt wird.

In Abbildung 4.2 ist das Vorgehen beim Reduzieren der Messungen zu erkennen. Die vertikalen roten Linien entsprechen Messanstößen, die durch die Optimierung ausgelassen werden.

Ohne die Optimierung wird für jeden Sensor die Messung nach erfolgtem Messvorgang direkt erneut angestoßen. Das Verhalten soll ohne nennenswerte Einbußen bei der Positionierung mit dieser Optimierung zu einer energiesparenderen Variante geändert werden. Der Einfluss auf die Ortungsgenauigkeit wird im Rahmen der Experimente überprüft.






Abbildung 4.2: Reduktion der Messungen bei Ausbleiben von Schritten [Eigene Darstellung]

### 4.2.3 Verwerfen entfernter Messungen

Wie bereits während des Hauptprojekts [Bar16b] vorgestellt, handelt es sich bei dem Verwerfen entfernter Messungen um eine simple Optimierung mit dem Ziel, einen großen Teil unwahrscheinlicher Messungen während des Vergleichs ignorieren zu können. Hierdurch sollen zum einen zusätzlich zum Filter Sprünge verhindert und zum anderen die Genauigkeit erhöht werden, da theoretisch nur diejenigen Positionen beachtet werden, die realistischerweise pro Zeitschritt erreicht werden können.

Theoretisch deshalb, da eben nur ein großer Teil unwahrscheinlicher Messungen verworfen wird und bei Messungenauigkeiten die Position, ähnlich zu der folgenden Optimierung der linearen Abschwächung, als an falscher Stelle fixiert angenommen werden kann. Das Verhältnis von Sprung- und Genauigkeitsverbesserung zu falscher Positionierung wird für diese Optimierung im Experimententeil untersucht.

Dem distanzbasierten Verwerfen von Messergebnissen liegt die menschliche Bewegungsgeschwindigkeit zugrunde, was folgendermaßen bereits im Hauptprojekt beschrieben wurde: „Hegewald definiert eine ‚sehr schnelle Ganggeschwindigkeit‘ als das 1,15 Fache der Körpergröße (vgl. [Heg10]). Es kann also selbst bei kleineren Messungenauigkeiten als unwahrscheinlich angesehen werden, dass sich ein Nutzer [...] des Systems schneller als  $3\text{ m/s}$  bewegt, weshalb diese[r Wert] als aufgerundete Grenze genutzt wird und weiter entfernte Messpunkte [als

die Strecke, die ein Mensch pro Sekunde zurücklegen wird,] keine Beachtung beim Abgleich finden“ [Bar16b, S. 11].

#### 4.2.4 Lineare Abschwächung

Ähnlich dem Verwerfen aller Messungen, die weiter als drei Meter von der aktuellen Position entfernt sind, ist die lineare Abschwächung dazu gedacht, den Einfluss physikalisch weit entfernter Messungen zu reduzieren. Die Idee dieser Optimierung basiert auf der Weighted k-Nearest Neighbors Filterung, bei der Messpunkten eine höhere Gewichtung zugewiesen wird, je näher sie der letztbekannten Position sind. Anstatt allerdings nur solche Messungen zu gewichten, die in den Durchschnitt einfließen, soll die lineare Abschwächung allen Messpunkten linear zu ihrem Abstand eine niedrigere Gewichtung zuordnen.

Hierzu wird beim Orten die Länge und Breite des Gebiets mit einbezogen, um die maximal mögliche Entfernung zur zuletzt bekannten Position bestimmen zu können. Der von 1 subtrahierte Anteil der Entfernung des Messpunkts zur Position von der maximal möglichen Entfernung gibt daraufhin die Gewichtung an, dargestellt in Formel 4.1.

$$weight = 1 - \frac{distance_{z_t, pos_t}}{\sqrt{width_{blueprint}^2 + length_{blueprint}^2}} \quad (4.1)$$

Problematisch an der linearen Abschwächung ist, ebenso vergleichbar mit dem Verwerfen entfernter Messungen, das Ignorieren zwar entfernter, aber dennoch möglicher Messungen. Geht ein Nutzer etwa einen von zwei sich teilenden Wegen, wird die Ähnlichkeit des weiter entfernten Wegs automatisch herabgestuft. Wird der falsche Weg erkannt, könnte im schlimmsten Fall die Position daraufhin in der Umgebung dieses Orts verweilen, da die korrekten Messungen fälschlicherweise nicht mehr hoch genug gewichtet würden. Sollte sich die lineare Abschwächung langfristig als grundsätzlich lohnenswert herauskristallisieren, könnte als Lösung des Problems in einer möglichen Weiterentwicklung die Abschwächung begrenzt oder statt der linearen zum Beispiel eine logarithmische Reduktion gewählt werden.

### 4.2.5 Dynamische Sensorgewichtung

Die dynamische Sensorgewichtung basiert auf der Idee, Sensoren mit geringem Messwertumfang einen verringerten Aussagewert zuzuordnen. Ein Mobilfunkmodul etwa, das nur sehr wenige unterschiedliche Werte ausgibt, würde in diesem Fall niedriger gewichtet werden als ein Bluetoothmodul, das eine deutlich höhere Bandbreite an möglichen Signalstärken unterscheiden kann.

Die Berechnung der Sensorgewichtungen erfolgt über die Varianz, was an den ersten Schritt des Kalman-Filters mit einer Dimension angelehnt ist (siehe Kapitel 3.5.2). Bei hoher Varianz sind die Abweichungen der Messungen vom Mittelwert entsprechend stark, weshalb die Gewichtung ansteigt, bei niedriger Varianz wird sie hingegen verringert. Um den Effekt zu begrenzen und eine zu hohe Gewichtung von solchen Sensoren zu verhindern, die aufgrund zu kurzer Einmesszeiten schwanken, können in IndoorGPS Sensoren nur einen Wert zwischen der halben und der doppelten Gewichtung annehmen. Die Berechnung hierfür kann Formel 4.2 entnommen werden.

$$\begin{aligned} avg_{sensor} &= \frac{\sum_{n=0}^N(diff_n)}{N} \\ \sigma_{sensor} &= \frac{\sqrt{\sum_{n=0}^N(diff_n - avg_{sensor})^2}}{N} \end{aligned} \quad (4.2)$$

$$weight_{sensor} = 0,5 \leq \sigma_{sensor} \leq 2$$

Die zu beantwortende Frage ist, ob das Reduzieren der Sensorgewichtung für jene Sensoren, deren Messungen nur geringfügig schwanken, tatsächlich eine Stabilisierung der Positionierung zur Folge hat, das Gegenteil eintritt und die Gewichtung die Positionierung negativ beeinflusst oder schließlich, ob keine erkennbaren Änderungen auftreten. Wie für die restlichen Optimierungen auch wird die Beantwortung der Frage in Kapitel 4.4.3 vorgenommen.

### 4.3 Nutzung

Für die Durchführung der Experimente und das Evaluieren der Verfahren wurde mit IndoorGPS eine Android App entwickelt. Die Benutzung der App folgt dabei immer den selben Schritten:

1. Auswahl der Lokalisierungsverfahren und -sensoren
2. Auswahl des Grundrisses und Angabe seiner ungefähren Maße
3. Einzeichnen der Pfade, auf denen die Daten erhoben werden sollen
4. Abschreiten der Pfade und Erhebung der Daten
5. Ortung und Überprüfung der angezeigten Positionen auf ihre Korrektheit

Die Auswahl der Lokalisierungsverfahren erfolgt auf einer Übersichtsseite innerhalb der App, ersichtlich in Grafik 4.3. Neben einzelnen Sensoren lassen sich auch sämtliche Optimierungen getrennt ein- und ausschalten, womit jede Kombination aus Sensor und Optimierung gesondert getestet werden kann.

Der Verfahrensauswahl folgt das Bestimmen eines Grundrisses. Falls kein geeigneter Grundriss vorliegt oder nur grobe, kurzfristige Ergebnisse ohne Vorbereitungszeit benötigt werden, steht ein generischer Grundriss zur Verfügung. Dieser entspricht einer simplen Einteilung des Gebiets in Rechtecke, sodass zumindest eine grundlegende Orientierung gegeben ist. Die Einbindung je eines generischen und eines geeigneten Grundrisses zeigen die Bildschirmfotos 4.4. Außerdem zu erkennen sind die Maße des Areals in der oberen rechten Ecke. Da die Maße ausschließlich für distanzbasierte Optimierungen, namentlich die lineare Abschwächung und dem Verwerfen entfernter Messungen, verwendet werden, sind die Daten nicht in jedem Fall zwingend erforderlich.

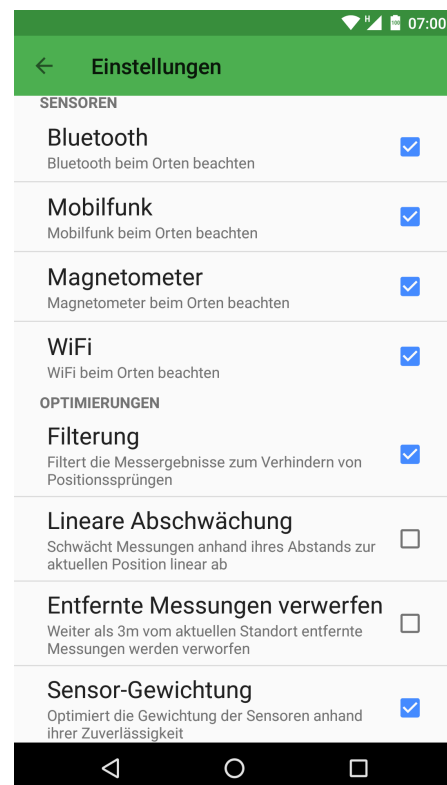


Abbildung 4.3: Auswahl der Lokalisierungsverfahren

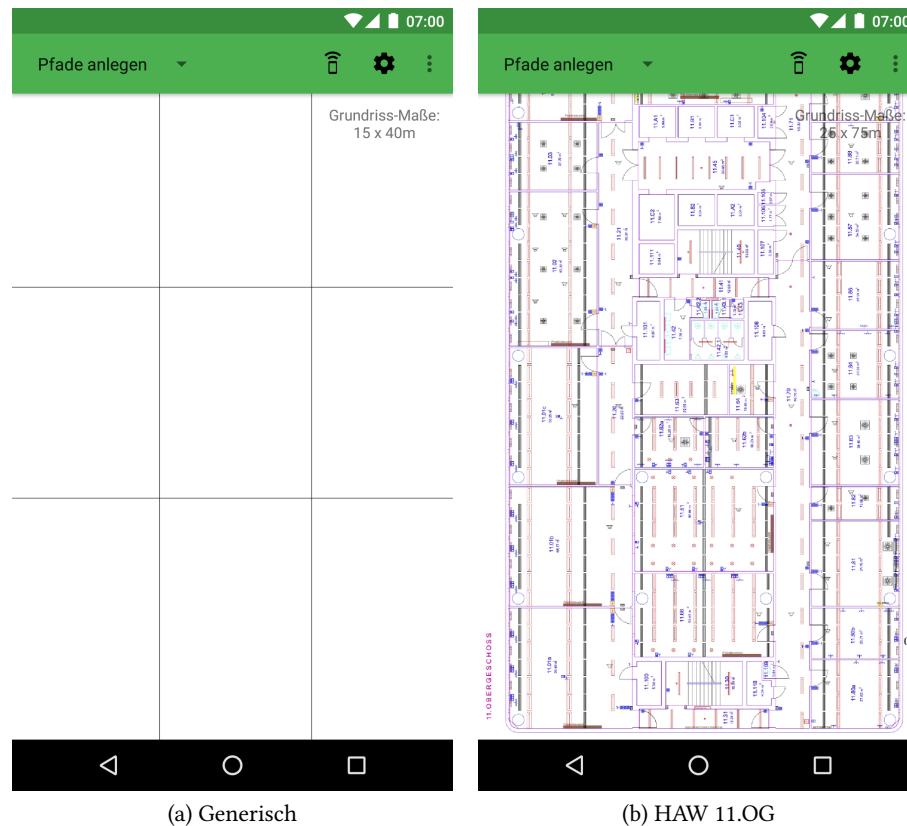


Abbildung 4.4: Eingebundener Grundriss in IndoorGPS

Ist der passende Grundriss ausgewählt, werden die abzuschreitenden Pfade eingezeichnet. Besonders für größere Karten, wie dem dargestellten Grundriss vom 11. Obergeschoss der HAW, ist dabei die Möglichkeit gedacht, die Ansicht mit zwei Fingern frei schieben und zoomen zu können. Um Schwankungen bei der Messung ausgleichen zu können, kann zudem ausgewählt werden, dass sich die eingezeichneten Pfade anschließend hin und zurück abschreiten lassen.

Das eigentliche Abschreiten entspricht der Offline-Phase des Fingerprintings und dient dem Mapping von Messungen auf Koordinaten der Karte. Die Koordinaten werden dabei äquidistant über den jeweils ausgewählten Pfad verteilt, weshalb eine langsame und gleichmäßige Ganggeschwindigkeit beim Aufzeichnen empfehlenswert ist. Die Verteilung könnte für eine Weiterentwicklung noch optimiert werden, indem die Messungen zum jeweiligen Auftrittszeitpunkt auf der Strecke hinterlegt werden. Bisher schien eine solche Optimierung allerdings noch nicht sinnvoll, da verhältnismäßig viele Messungen auf sehr kurzen Strecken getätigt

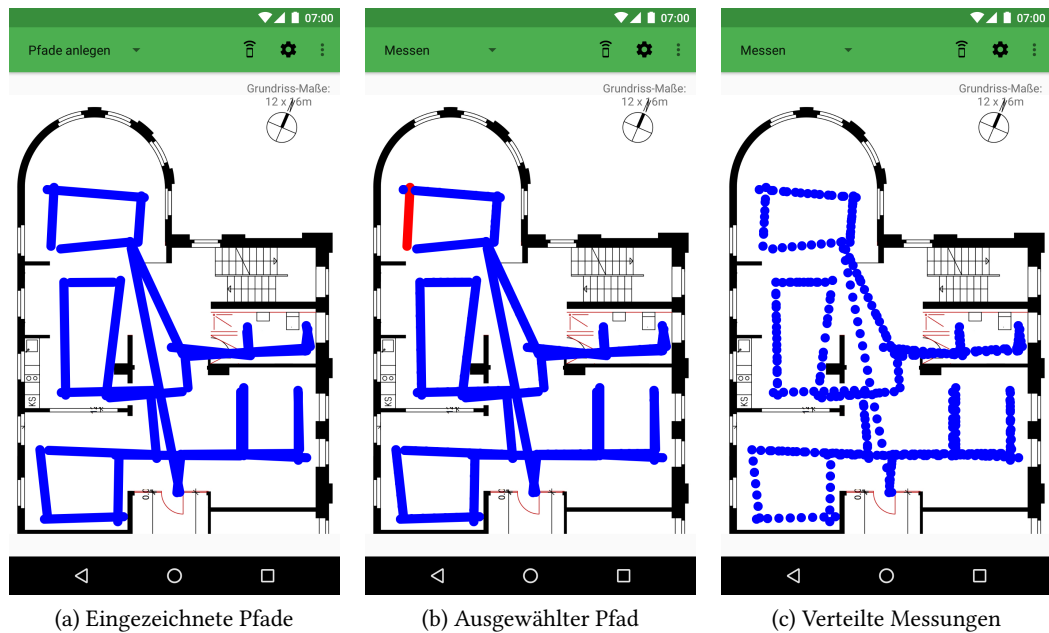


Abbildung 4.5: Abzuschreitende Pfade und hierauf verteilte Messungen

wurden und eine Genauigkeitssteigerung durch die verbesserte Verteilung in diesem Szenario zumindest fraglich ist.

Die Auswahl des Pfades geschieht beim Abschreiten durch einen Tap auf einen beliebigen Ort auf der Karte, wobei nach jedem Tap der nächste Pfad in der Reihenfolge der Einzeichnung markiert wird, wie sich [Abbildung 4.5b](#) entnehmen lässt. [Abbildung 4.5c](#) zeigt schließlich die auf den Pfaden verteilten Messungen.

Wurden bis hierhin alle Schritte durchgeführt, kann das Smartphone von nun an seine Position bestimmen. Je nach Auswahl der Anzeigeeinstellungen werden neben der Position, die als grüner Punkt dargestellt wird, noch weitere Informationen eingeblendet. Dies sind die nächstähnlichen Positionen, die potenziell auch für die Filterung genutzt werden, erkennbar an der roten




Abbildung 4.6: Lokalisierung und Zusatzinformationen

Färbung; darüber hinaus die grobe Genauigkeit, als bläulich gefärbter Kreis zwischen der Position und der am weitesten entfernten nächsten Schätzung. Schließlich können noch die Ähnlichkeiten als Prozentangabe an jedem Messpunkt eingeblendet werden. Mit Ausnahme der Ähnlichkeiten, die eher für die Entwicklung gedacht sind und bei der Nutzung schnell zu Unübersichtlichkeit führen, sind alle Informationen in Grafik 4.6 zu sehen.

### 4.4 Messungen

Diejenigen Verfahren, die sich durchgesetzt haben, wurden im Anschluss an die Entwicklung in mehreren Experimenten mit jeweils unterschiedlichen Zielen einem Praxiseinsatz unterzogen. Im Verlauf dieses Kapitels werden als erstes die Fragen vorgestellt, die es experimentell zu beantworteten galt, sowie die Orte, an denen diese untersucht wurden. Es folgt die Vorstellung und Besprechung der Messergebnisse, einschließlich der Einflüsse, die die einzelnen Sensoren, ihre Fusion sowie die Optimierungen auf diese Ergebnisse hatten. Im Anschluss wird das Praxiskapitel mit einem technischen Fazit sowie dem Ausblick auf künftige Weiterentwicklungen abgeschlossen.

#### 4.4.1 Zu beantwortende Fragen

Die primäre Frage, die an das entwickelte System gestellt wird, lautet:

„Ist mit den implementierten Ansätzen eine zuverlässige, raumweite Positionserkennung unabhängig vom Gebäude mit IndoorGPS erreichbar?“

Diese Frage lässt sich in drei speziellere Fragen aufbrechen:

1. „Ist eine Positionserkennung mit IndoorGPS grundsätzlich erreichbar und sind die implementierten Optimierungen für diesen Zweck hilfreich?“
2. „Ist eine raumweite Positionserkennung mit IndoorGPS erreichbar?“
3. „Ist die zuverlässige Positionserkennung unabhängig vom Gebäude mit IndoorGPS erreichbar?“

Jede dieser drei Fragen bildet im Folgenden die Grundlage für jeweils einen Versuch:

1. HAW Gebäude - Innerhalb der 11. Etage des HAW Hamburg Gebäudes wird geprüft, ob die Positionierung unter Laborbedingungen grundsätzlich möglich ist und inwieweit sich die Optimierungen auf die Erkennung auswirken.
2. Creative Space - Die Genauigkeit der Positionierung wird im Creative Space anhand eines Referenzsystems geprüft.
3. Living Place - Ob die implementierten Ansätze ausreichen, unter herausfordernden Praxisbedingungen eine zuverlässige Positionierung zu gewährleisten, wird im Living Place untersucht.

Der Aufbau dieser Versuche wird in den folgenden Abschnitten erläutert.

### 4.4.2 Experimentaufbauten und Versuchsorte

Die drei Versuchsorte erforderten zum Beantworten der gestellten Fragen sich jeweils unterscheidende Herangehensweisen. Begonnen wurden die Versuche im 11. Obergeschoss der HAW Hamburg am Campus Berliner Tor.

#### HAW Gebäude

Um herauszufinden, ob die Positionierung unter Laborbedingungen möglich ist und sich hierbei die implementierten Optimierungen positiv auswirken, wurde innerhalb der HAW Hamburg abseits der regulären Vorlesungszeiten und des Alltagsbetriebs gemessen. Ein Eindruck des Areals lässt sich durch Abbildung 4.7 gewinnen.

Ingesamt wurden hierzu neun Versuche durchgeführt: Je einen pro Sensor (Bluetooth, Mobilfunk, Magnetometer und WiFi), einen mit fusionierten Daten und jeweils einen pro Optimierung (Filterung, lineare Abschwächung, verworfene Messungen und Sensor-Gewichtung) mit fusionierten Daten. Entgegen dem Vorsatz, ein System zu untersuchen, das bestenfalls im Hintergrund läuft, wurde das Gerät während der gesamten Zeit in der Hand und vor dem Körper gehalten, weil dies das reproduzierbarste Ergebnis ermöglichte.

Aufgrund seiner Größe bot der Versuchsort abseits des Alltagsbetriebs gute Bedingungen, grob die Positionierung von IndoorGPS einzuschätzen und den Einfluss der Optimierungen zu





Abbildung 4.7: 11. Obergeschoss der HAW Hamburg

beobachten. „Grob“, da in der HAW kein Referenzsystem installiert ist, weshalb die Einschätzung nur nach Augenmaß vorgenommen wurde. Eine feinere, gesonderte Bestimmung der Genauigkeit war aus diesem Grund nicht Teil des Experiments, sondern wurde erst im nächsten Versuch beachtet, der im folgenden Abschnitt beschrieben wird. Für eine Einschätzung der Tendenz reichte die Beobachtung allerdings aus.


### **Creative Space**

Das Creative Space bietet für die Bestimmung der Genauigkeit von IndoorGPS eine große Fläche, die mit dem ARTTRACK System<sup>2</sup> ausgestattet ist. Bei ARTTRACK, was für Advanced Realtime Tracking steht, handelt es sich um ein mit Infrarotlichtpulsen arbeitendes optisches Tracking-System, das laut Hersteller das weltweit genaueste und zuverlässigste Kamerasys-

---

<sup>2</sup><http://www.ar-tracking.com/products/tracking-systems/arttrack-system>,  
Abruf: 27.01.17

tem zu diesem Zweck darstellt<sup>3</sup>. Durch die optische Arbeitsweise liegt die Genauigkeit von ARTTRACK deutlich über der mobiler Lösungen und ist damit eine sehr gute Möglichkeit zur Leistungsüberprüfung von IndoorGPS.



(a) Das ARTTRACK System<sup>4</sup>

(b) Optical Target Set<sup>5</sup>

Abbildung 4.8: ARTTRACK und das für die Ortung zu tragende Optical Target Set

ARTTRACK besteht aus mehreren der in Abbildung 4.8a zu sehenden Kameras, die jeweils die Reflexionen der ausgesendeten Infrarotpulse empfangen, womit nicht nur auf die Position von Objekten, sondern auch auf ihre Orientierung im dreidimensionalen Raum geschlossen werden kann. Hierfür wird das sogenannte Optical Target Set benötigt, in Darstellung 4.8b abgebildet, das aus fest zueinander angeordneten reflektierenden Kugeln besteht, die so aus jeder Perspektive die Berechnung von Position und Orientierung ermöglichen.



Abbildung 4.9: Ubisense RTLS<sup>6</sup>

---

<sup>3</sup><http://www.ar-tracking.com/products/tracking-systems/arttrack-system/arttrack5>, Abruf: 27.01.17

<sup>4</sup>ebd.

<sup>5</sup><http://www.ar-tracking.com/products/motion-capture/optical-target-set>, Abruf: 27.01.17

Neben ARTTRACK ist auch das Ubisense RTLS (Real-Time Location System)<sup>7</sup> System installiert, dargestellt in Abbildung 4.9. Das auf Ultrabreitband-Funksignale setzende System ist ebenfalls auf die Ortung von Objekten im dreidimensionalen Raum ausgelegt, verzichtet aber auf eine Orientierungsbestimmung. Zum Zeitpunkt der Messungen war das System allerdings noch nicht kalibriert und stand damit nicht als Referenzsystem zur Verfügung.



Abbildung 4.10: Aufbau der Creative Space Testfläche

Die absolute Genauigkeit von IndoorGPS zu bestimmen ist äußerst schwierig, da nur diskrete Messpunkte wiedererkannt werden. Darüber hinaus müssen an jedem Punkt die Signale mit einiger Einspielzeit aufgezeichnet werden, weshalb eine zu kleinschrittige Aufteilung der Fläche extrem zeitaufwändig ist. Aus diesem Grund wurde die Fläche in immer kleinere Felder aufgeteilt, bis diese von IndoorGPS nicht mehr zuverlässig voneinander unterschieden werden konnten. Der Aufbau des Creative Space mit den beiden Referenzsystemen ist in Abbildung 4.10 zu sehen, wobei Ubisense und ARTTRACK in der oberen linken und rechten Ecke installiert sind.

---

<sup>6</sup><https://ubisense.net/de/products/rtls-plattform>, Abruf: 28.01.17

<sup>7</sup>ebd.

ARTTRACK wurde hierzu als virtuelles Maßband genutzt und das Smartphone mit einem ART Marker, einem einzelnen Reflektorteil des Optical Target Sets, versehen, wie sich Grafik 4.11a entnehmen lässt. Anschließend wurde das Smartphone jeweils in die Mitte eines Feldes an eine fest markierte Stelle gelegt, die Signale über einen Zeitraum von 20 Sekunden gesammelt und mit dem nächsten Feld fortgefahren, zu sehen in Grafik 4.11b. Hierfür wurde die im ersten Versuch ermittelte genaueste Kombination von IndoorGPS ausgewählt, die aus allen Sensoren und der Filterung bestand, allerdings keine Optimierung enthielt, da es sich rein um stationäre Messungen handelte. Die fünf vorhandenen Beacons wurden darüber hinaus auf alle vier Ecken der Fläche und die Flächenmitte verteilt.

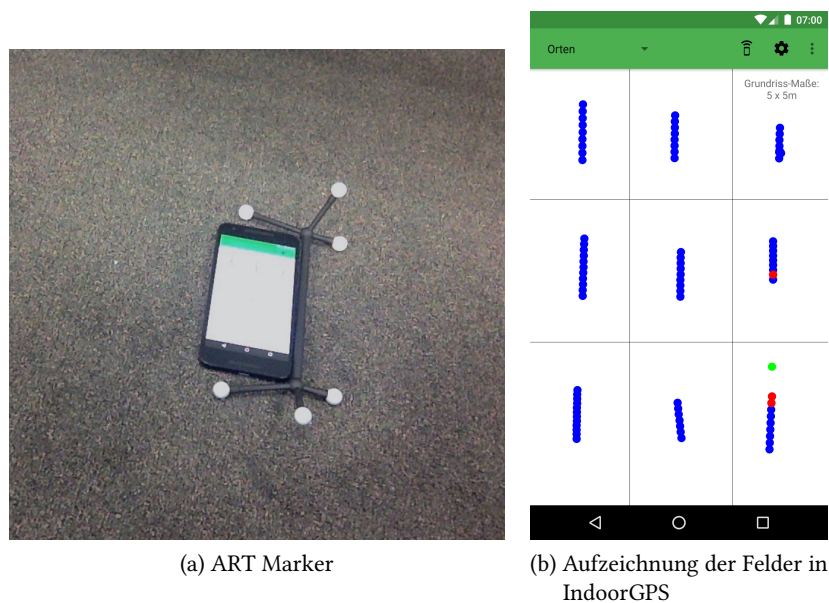


Abbildung 4.11: Versuchsaufbau im Creative Space

Die Aufteilung wurde in zwei Teilschritten durchgeführt: Zuerst geschah die Teilung in vier Teilflächen, die von IndoorGPS noch problemlos unterschieden werden konnten. Im nächsten Durchlauf wurde die Fläche weiter auf diesmal neun Felder aufgeteilt, was bereits zu deutlichen Ungenauigkeiten führte, die ebenfalls in Abbildung 4.11b an der Position zwischen den zwei Feldern erkennbar sind. Die Berechnung der Genauigkeit wird zusammen mit den Ergebnissen in Abschnitt 4.4.4 vorgestellt.

## Living Place

Den letzten Versuchsort stellt das Living Place Hamburg dar, das bereits im Kapitel **Smart Environments und Zielsetzung** vorgestellt wurde. Das Ziel bestand diesmal darin, die Praxistauglichkeit der implementierten Verfahren unter erschwerten Bedingungen zu testen. „Erschwerte Bedingungen“ bedeutet konkret das Vorhandensein dutzender, teils sehr schwacher und sich überschneidender WiFi-Netze auch aus den umgebenden Gebäuden. Darüber hinaus sind weitere für die Vernetzung im Smart Home notwendige Funkwellen, unter anderem etwa Bluetooth, gemeint. Zuletzt herrschte Alltagsbetrieb vor, es waren also stets mehrere Personen anwesend, die sich als zusätzliche Störfaktoren auf die Fingerprints auswirkten.



(a) Ess-, Koch- und Wohnbereich



(b) Schlafbereich und Eingang zum Badezimmer

Abbildung 4.12: Versuchsaufbau im Living Place

Das Living Place ist in den Fotos 4.12 zu erkennen. 4.12a zeigt den Essbereich vorne links, dahinter die Küche und schließlich den Wohnbereich im Hintergrund; 4.12b den Schlafbereich und auf der linken Seite den Eingang zum Badezimmer. Mittig zwischen den abgebildeten Bereichen befindet sich der Gang vom Eingang bis zum Wohnbereich.

Aufgrund dieser erschwerten Bedingungen konnte die Stabilität des Systems auch bei deutlich herabgesetzter Zuverlässigkeit besonders der Funksensoren beobachtet werden. Zudem ermöglichten sie es, zu testen, ob ein System mit deterministischem Fingerprinting und ohne relative Ortung noch immer in der Lage ist, eine ausreichende Positionierung sicherzustellen. Das Einmessen und Abschreiten geschah ausschließlich in der Nordhälfte des Living Place, im Renderbild 4.13 entspricht dies der rechten Hälfte. Der Grundriss hierzu ist zusammen mit den

abgeschrittenen Pfaden in den Abbildungen 4.5 sowie 4.6 zu finden.




Abbildung 4.13: Renderbild des Living Place Hamburg [EKV<sup>+</sup>11, p.3]

Auch im Living Place ist die Ubisense RTLS Hardware installiert, allerdings stand diese mangels Kalibrierung zum Testzeitpunkt nicht zur Verfügung. Da jedoch, vergleichbar mit dem Versuch im HAW Gebäude, keine feine Genauigkeit untersucht wurde, konnte auf die Nutzung eines Referenzsystems erneut verzichtet werden. Die Bluetooth-Beacons wurden wieder möglichst gleichmäßig frei in der Wohnung verteilt: Je ein Beacon auf dem Esstisch, der Theke zwischen Essbereich und Küche, der Kücheninsel, dem Sideboard zwischen Schlafbereich und Gang sowie dem TV-Board im Wohnbereich. Ebenfalls vergleichbar mit dem Versuch im HAW Gebäude ist die Haltung des Smartphones in der Hand und vor dem Körper.

### 4.4.3 Ergebnisse der Messungen im HAW Gebäude

Für den Versuch innerhalb der HAW Hamburg wurden die mit einer deutlich früheren Version der Software ermittelten Ergebnisse des Hauptprojekts [Bar16b] um Messreihen mit dem Mobilfunk-Sensor und damit auch einer aktualisierten Variante der Sensor-Fusion, der Filterung sowie der Optimierungen „Lineare Abschwächung“ und „Sensor-Gewichtung“ ergänzt. Da an der Erkennung mittels WiFi, Magnetometer und Bluetooth sowie der bereits untersuchten Optimierung des Verwerfens entfernter Messpunkte keine Änderung vorgenommen wurde, sind deren Ergebnisse ebenfalls in Tabelle 4.1 auffindbar.

Die Aufteilung der Etage verlief bei der Positionierung exakt so wie im ersten Durchlauf im Rahmen des Hauptprojekts und teilt die zu ortenden Bereiche in einen Fahrstuhlbereich, einen Arbeitsraum und den langen Flur auf, der wiederum in drei Gangabschnitte „Nord“, „Mitte“ und „Süd“ unterteilt ist. Die ergänzten Messdaten wurden dabei in zwei Durchläufen erhoben.

Der Mobilfunk als neue Sensorart bot aufgrund geringer Empfangsunterschiede grundsätzlich die erwartete mangelhafte Ortungsqualität in Innenräumen, ermöglichte allerdings äußerst zuverlässig die Erkennung des Bereichs um den Fahrstuhl herum, da hier der Empfang erkennbar einbrach. Zusammen mit dem Magnetometer führte diese Auffälligkeit zu verbesserten Ergebnissen bei der Sensor-Fusion gegenüber der Variante des Hauptprojekts. Die Verschlechterung blieb auch deswegen aus, weil der Empfang abseits des Fahrstuhls kaum schwankte und daher die Differenzen bei der Ortung in den anderen Bereichen vernachlässigbar gering ausfielen.

Positive Ergebnisse ermöglichte die Filterung, die zu einer erheblichen Reduzierung der Positionssprünge beitrug und besonders im Nordbereich nochmals zu etwas besseren Ergebnissen im Vergleich zur Sensor-Fusion ohne Filterung führte, da hier häufig das Mittel der drei ähnlichsten Messungen näher an der tatsächlichen Position lag als die ähnlichste Einzelmessung. Die Filterung führte durch die Mittelung allerdings auch zu Positionen in unbegehbaren Bereichen, die sich jedoch in den meisten Fällen schnell wieder relativierten und sich damit in diesem Szenario nicht als auffallend hinderlich herausstellten.

Die Ergebnisse des Versuchs sind Tabelle 4.1 zu entnehmen. Der Trennstrich innerhalb einer Zelle stellt dabei jeweils die Schwankung der Werte zwischen den Durchläufen dar. Eine kurze Rekapitulation der bereits vorhandenen Ergebnisse aus dem Hauptprojekt dient der besseren Einordnung der in dieser Arbeit ergänzten Werte.

Die allein auf WiFi beschränkte Positionierung ermöglichte bereits relativ genaue Ergebnisse in einem Teil des Bereichs, neigte aber zu starken Schwankungen im Fahrstuhlbereich. In diesem Teil des Gebäudes führte vermutlich die Abschwächung der empfangenen WiFi-Netze zu starken Messungenauigkeiten. Zudem stellte sich die recht langsame Scanrate als nachteilig heraus, da sich die Position somit nur träge aktualisierte.

---

<sup>8</sup>Ergebnis trat deutlich verzögert auf

<sup>9</sup>Führte zu fixierter Position

#### 4 IndoorGPS

Bereich	WiFi	Magnetometer	Bluetooth	Mobilfunk	Sensor-Fusion	Filterung	Verwerfen	Abschwächung	Gewichtung
Gang(Nord)	+	-	o	o	o/+	+	+	-	o/+
Raum	+	o	+	-	+	+	+	o	+
Gang(Mitte)	o/+	+	o	-	o/+	o/+	o/+ <sup>8</sup>	o	o/+
Fahrstuhl	-	+	o	+	+	+	+	+ <sup>9</sup>	+
Gang(Süd)	+	-	+	-	+	+	o/+ <sup>8</sup>	o	+

Tabelle 4.1: Ergebnisse der Messungen im 11. OG des HAW Gebäudes

- + : Praktisch alle Schätzungen liegen im abgeschrittenen Bereich
- o : > 50% der Schätzungen liegen im abgeschrittenen Bereich
- : < 50% der Schätzungen liegen im abgeschrittenen Bereich

Das Magnetometer hingegen hinterließ einen guten Eindruck bei der Ortung im Fahrstuhlbereich, was die Annahme der verbesserten Ortung in Bereichen mit Magnetfeldsignaturen verstärkenden Metallstrukturen unterstützte. Zusätzlich war eine im Vergleich zum WiFi deutlich erhöhte Aktualisierungsrate erkennbar, allerdings auch eine stark eingeschränkte Ortbarkeit in Bereichen abseits des Fahrstuhls, da hier die Signaturunterschiede zu gering für eine zuverlässige Ortung waren.

Die im Hauptprojekt erkannte Komplementarität zwischen WiFi- und Magnetfeldortung, die besonders im Fahrstuhlbereich sehr schlechte (WiFi-Sensor) beziehungsweise sehr gute (Magnetometer) Ergebnisse lieferten, wurde ebenfalls im Projekt Magicol [SBS<sup>+</sup>15] beobachtet. Als Erklärung ziehen die Autoren hier die globalen und lokalen Signaturdifferenzen zu Rate: Während sich Magnetfelder global gesehen eher wiederholen, aber auf lokaler Ebene gerade durch Metallstrukturen feine Unterschiede aufzeigen können, sind WiFi-Netze konzeptbedingt global unterschiedlich (an unterschiedlichen Orten werden auch unterschiedliche Netze empfangen), neigen jedoch dazu, sich lokal zu wiederholen. Die Fusion beider Sensoren stelle daher eine ideale Ergänzung dar, was so auch im Rahmen des Hauptprojekts festgestellt werden konnte.

Bluetooth ermöglichte eine alles in allem durchschnittliche bis gute Positionierung. Neben dem Nachteil, dass vor der Ortung Beacons verteilt werden mussten, wurde eine gegenüber WiFi nochmals erhöhte Aktualisierungsrate beobachtet, die zwar softwareseitig verringert werden konnte; hierdurch verringerte sich jedoch ebenfalls die Zeit für die Identifizierung der Sender. In einem kurzen Test für die vorliegende Arbeit führte eine Erhöhung der Aktualisierungsrate weder zu deutlich besseren noch schlechteren Ergebnissen und wurde daher in der



Standardeinstellung belassen.

Bei der Durchführung der Versuche im Rahmen dieser Arbeit wurden nochmals die Sprünge der einzelnen Sensoren nach der Filterung beobachtet. Hierbei war zu erkennen, dass besonders das Magnetometer zu starken Sprüngen neigte, was sich mit den schwachen Signaturunterschieden sowie der schnellen Aktualisierungsgeschwindigkeit erklären lässt. Als etwas weniger sprunganfällig stellte sich der WiFi-Sensor heraus, als besonders sprungarm die Ortung mittels Bluetooth. Die Ortung mithilfe des Mobilfunkmoduls sprang praktisch überhaupt nicht, was jedoch aufgrund der äußerst geringen Empfangsunterschiede das zu erwartene Ergebnis darstellte. Eine Ortung mittels Mobilfunk war nur im Fahrstuhlbereich und zum Teil im Nordbereich möglich, da an diesen Stellen das Signal stark abgeschwächt wurde. An jedem weiteren Ort wurde bestmöglicher Mobilfunkempfang ermöglicht, womit zwar keinerlei Differenz zur Ortung genutzt werden konnte, jedoch auch keine Sprünge auftraten.

Von der Filterung abgesehen führten die implementierten Optimierungen zu zwiespältigen Ergebnissen. War beim Verwerfen entfernter Messungen während des Hauptprojekts noch eine mit der mittlerweile hinzugefügten Filterung vergleichbare Sprungreduktion besonders im Fahrstuhlbereich erkennbar, führte dies bereits zu Verzögerungen bei der Positionierung. Die lineare Abschwächung verstärkte dieses Verhalten noch und führte beim ersten Versuch zu einer Fixierung der Positionsberechnung an dieser Stelle, die sich erst beim Zurücksetzen und Neubeginn der Messungen löste. Eine Möglichkeit zur Verbesserung könnte hierbei eine regelbasierte Abschwächung sein, die deaktiviert wird, wenn der Schrittzähler aktiv ist, sich die Position aber längere Zeit nicht aktualisiert hat.

Durch die Optimierung der Sensorgewichtung konnte hingegen keinerlei nennenswerter Einfluss auf die Ergebnisse beobachtet werden. An dieser Stelle ist deshalb noch eine zusätzliche Untersuchung empfehlenswert, um zu ermitteln, ob dies mit der ausbleibenden Aktualisierung während der Ortung oder dem Testszenario im Zusammenhang steht.

Zusammenfassend kann die Frage nach der grundsätzlichen Ortungsmöglichkeit unter Laborbedingungen klar bejaht werden. Die Auswirkungen der Optimierungen, abgesehen von der Filterung, stellten sich hingegen als wenig nutzbringend heraus und sind aufgrund der aufgeführten Nachteile daher, zumindest in der aktuellen Form, nicht grundsätzlich empfehlenswert.

#### 4.4.4 Ergebnisse der Messungen im Creative Space

Um die Genauigkeit der Anwendung bestimmen zu können, wurde im Creative Space die Abweichung zwischen IndoorGPS und Referenzsystem genutzt. Diese entspricht dabei jeweils der Länge eines Vektors vom Mittelpunkt des vom ARTTRACK gemessenen Feldes zum Mittelpunkt des von IndoorGPS gemessenen Feldes. Da die Filterung ein Wandern der Position zwischen zwei Feldern bewirkte, wurde in diesem Fall für die Abweichung der Mittelpunkt zwischen beiden Feldern angenommen. Das Vorgehen kann Formel 4.3 entnommen werden.

$$distance = \left| \overrightarrow{pos_{ARTTRACK}} - \frac{\overrightarrow{pos1_{IndoorGPS}} + \overrightarrow{pos2_{IndoorGPS}}}{2} \right| \quad (4.3)$$

Die Messungen wurden jeweils insgesamt drei Mal nach kurzer Einspielzeit genommen und waren reproduzierbar. Einzig Feld 7 schwankte - im Gegensatz zum ersten Versuchsaufbau mit vier Feldern - erst bei den letzten zwei Messungen zwischen Feld 7 und 8. Die Ergebnisse des zweiten Versuchsaufbaus im Creative Space finden sich in Tabelle 4.2. Die Felder in der Tabelle sind entsprechend ihrer abgeschrittenen Position von vorne links (VL) über die Mitte (M) bis hinten rechts (HR) gekennzeichnet. Die X- und Y-Koordinaten beziehen sich auf die von ARTTRACK ausgegebenen Abweichungen vom Mittelpunkt des Bereichs und reichen grob von  $-2,5m$  bis  $2,5m$  in beide Richtungen.

Unter optimalen Bedingungen liegt die durchschnittliche Abweichung von IndoorGPS gegenüber dem ARTTRACK Referenzsystem somit bei etwa  $1,6m$ , die maximale Abweichung bei etwa  $5m$ . Die Genauigkeit lässt sich zwar aufgrund der in Abschnitt 4.4.2 aufgeführten Punkte nur schwer feiner bestimmen (hierfür ist der probabilistische Ansatz mit seiner freien Positionierung innerhalb der eingemessenen Fläche besser geeignet). Allerdings kann die anfangs gestellte Frage „Ist eine raumweite Positionserkennung mit IndoorGPS erreichbar?“, kann also eine Positionierung innerhalb weniger Meter erreicht werden, mit der ermittelten durchschnittlichen Genauigkeit grundsätzlich bejaht werden.

#### 4.4.5 Ergebnisse der Messungen im Living Place

Die Bedingungen des simulierten Praxisbetriebs im Living Place stellen ein Worst-Case-Szenario für die Positionierung dar. Durch den gewöhnlichen Betrieb (Mitarbeiter anwesend,

<i>EchtePosition</i>	<i>IndoorGPS</i>	<i>ARTTRACK (x   y)</i>	<i>Abweichung</i>
<i>Feld 1 (VL)</i>	Feld 1	Feld 1 (2,44m   -2,61m)	0m*
<i>Feld 2 (ML)</i>	Feld 3	Feld 2 (-1,0m   -2,55m)	1,17m
<i>Feld 3 (HL)</i>	Feld 3	Feld 3 (-2,17m   -2,54m)	0m*
<i>Feld 4 (HM)</i>	Feld 3	Feld 4 (-2,12m   -0,14m)	2,40m
<i>Feld 5 (MM)</i>	Feld 1/5	Feld 5 (0,05m   0,07m)	2,16m
<i>Feld 6 (VM)</i>	Feld 1	Feld 6 (2,48m   -0,09m)	2,52m
<i>Feld 7 (VR)</i>	Feld 7/8	Feld 7 (2,50m   1,86m)	1,25m
<i>Feld 8 (MR)</i>	Feld 3	Feld 8 (0,0m   1,99m)	5,02m
<i>Feld 9 (HR)</i>	Feld 9	Feld 9 (-2,0m   2,01m)	0m*
<i>Durchschnitt</i>			1,61m

Tabelle 4.2: Ergebnisse des Vergleichs IndoorGPS / ARTTRACK im Creative Space

\* Da von IndoorGPS nur das Feld erkannt werden kann, wird als Position bei beiden Systemen die selbe Koordinate angenommen

Fenster geöffnet, viele schwache Funkwellen durch Gebäude in der Umgebung und das Smart Home) und offene Bereiche statt geschlossener Zimmer ließ sich beobachten, dass in jedem Bereich anfangs Positionssprünge deutlich zunahmten und nach kurzer Wartezeit der Aufenthaltsort nicht mehr eindeutig bestimmbar war.

Die Ergebnisse des Versuchs sind Tabelle 4.3 zu entnehmen. Die Bestimmung des Aufenthalts im Badezimmer war praktisch nicht möglich, der Wohnbereich wurde nur unregelmäßig erkannt. Im südlichen Teil funktionierte die Ortung grundsätzlich etwas besser: Die Positionierung im Schlaf- und Essbereich war hier in einigen Fällen in genauerem Maße gegeben als die reine Erkennung des Bereichs, jedoch war selbst in diesen Teilen des Living Place keine ausreichende Zuverlässigkeit mit dem Smartphone erreichbar.

Generell waren nur geringe Schwankungen zwischen den Ähnlichkeiten erkennbar, weshalb selbst kleinere Ungenauigkeiten bereits zu falschen Ergebnissen führten: Statt in der Küche wurde beispielsweise regelmäßig ein Standort im Ess- und Wohnbereich als Position ausgegeben. Die Folgen einer solchen Fehlererkennung werden im Fazit des Kapitels erneut aufgegriffen.

<i>Bereich</i>	<i>Erkennung</i>
<i>Schlafbereich</i>	o
<i>Essbereich</i>	o
<i>Kochbereich</i>	-
<i>Gang</i>	-
<i>Wohnbereich</i>	o
<i>Badezimmer</i>	-

Tabelle 4.3: Ergebnisse der Messungen im Living Place

- + Praktisch alle Schätzungen liegen im abgeschrittenen Bereich
- o >50% der Schätzungen liegen im abgeschrittenen Bereich
- <50% der Schätzungen liegen im abgeschrittenen Bereich

Die Optimierungen „Messungen verwerfen“ und „lineare Abschwächung“ führten nach kurzem Test zu unveränderlichen Positionsangaben, waren also in diesem Szenario hinderlich und wurden deshalb nicht genutzt.

Als Zusammenfassung des Versuchs lässt sich damit festhalten, dass „die zuverlässige Positionserkennung unabhängig vom Gebäude mit IndoorGPS“ mit den implementierten Verfahren unter herausfordernden Bedingungen nicht gewährleistet werden kann. Welche Schritte unternommen werden sollten, um sich diesem Ziel zu nähern, ist ebenfalls Teil des folgenden Zwischenfazits.

## 4.5 Zwischenfazit und technischer Ausblick

Durch die Entwicklung einer Anwendung konnten die gewonnenen Erkenntnisse des Theorie-teils dieser Arbeit in der Praxis getestet und erste Verfahrenskombinationen auf ihre Positionierungsleistung hin untersucht werden. Hierbei stand die Frage im Mittelpunkt, ob hiermit eine zuverlässige, raumweite Positionserkennung unabhängig vom Gebäude erreichbar ist.

Diese Frage kann zum jetzigen Zeitpunkt weder gänzlich bejaht noch verneint werden.

Unter Laborbedingungen ist die Ortung dank der Fusion mehrerer Sensoren und der anschließenden Filterung der Ergebnisse zu jeder Zeit möglich, wenn auch nicht immer allzu genau. Im besten Fall lässt sich die Position mit einer Genauigkeit von unter zwei Metern bestimmen, im schlechtesten ist dies auch unter Laborbedingungen nur deutlich ungenauer möglich.

Unter unvoreilhaftem, praxisähnlichen Bedingungen versagt die entwickelte Lösung unter dem gegebenen Gesichtspunkt einer zuverlässigen Positionserkennung unabhängig vom Gebäude. Eine stabile Ortung, im Sinne der kontinuierlichen Erkennung des Aufenthaltsbereichs, kann mit der aktuellen Implementierung nicht gewährleistet werden. Das bereits angedeutete Beispiel der Verwechslung von Koch- und Wohnbereich hieße auf die Kontexterkenkung übertragen zum Beispiel, dass statt Rezepten Informationen zum TV-Programm angezeigt würden, die Verwechslung von Schlafbereich und Küche könnte dazu führen, dass der Schlaf unterbrochen und das Licht in der Küche angeschaltet würde und so weiter.

Die auf den ausgewählten Verfahren basierende Lösung ist aktuell also weniger für feingranulare Anwendungsfälle wie die Kontexterkenkung in der Wohnung geeignet, aber unter Umständen bereits für Fälle sinnvoll, die mit gröberen Ergebnissen zurechtkommen. Beispiele wären Szenarien, in denen mit größerer Fehlertoleranz und längerfristigen Durchschnitten gearbeitet werden kann, wie das Auffinden von Nutzfahrzeugen oder Fertigungsteilen in der Industrie. Diese Orte zählen zudem aktuell zu den Einsatzorten von Systemen wie dem Ubisense RTLS, sodass eine Weiterentwicklung auf diesem Gebiet zu einer deutlichen Kostenersparnis gegenüber proprietären Lösungen führen könnte.

Ein weiteres Anwendungsszenario ist die Verbesserung von Indoor Maps in weitläufigen öffentlichen Gebäuden wie Flughäfen oder Einkaufszentren. Aktuell am Markt erhältliche Lösungen stellten sich nach einem kurzen Test in einem Einkaufszentrum in der Genauigkeit gegenüber der entwickelten Lösung als unterlegen heraus. Auch hier könnte sich also bereits ein Einsatz der Verfahren lohnen. Sinnvoller wäre hierzu allerdings ein crowdbasierter SLAM-Ansatz, bei dem die Positionierung zeitgleich mit der Verbesserung der Karten geschieht. Hiermit würden gleich eine ganze Reihe von Problemen der aktuellen Implementierung gelöst, etwa das aufwändige Einmessen in der Offline-Phase, die regelmäßige Rekalibrierung der

Fingerprints oder das Sammeln von Daten mit mehr als einem Gerät.

Um die Genauigkeit und Zuverlässigkeit des einzelnen Geräts zu verbessern, hat sich im Verlauf der Arbeit das probabilistische Vorgehen als das zukunftssträchtigere Verfahren gegenüber dem deterministischen Ansatz herausgestellt. Hierfür würde eine relative Ortung benötigt, die gleichzeitig Grundlage für die SLAM-Idee wäre und mit dem Kalman- und dem Partikel-Filter gänzlich andere Filterarten mit teils deutlich besseren Ergebnissen im Vergleich zum Nearest Neighbors Filtering ermöglicht. Sinnvoll ist bei diesem Vorgehen ein zentraler Server, der die Messdaten verwaltet und unter Umständen einige Berechnungen, etwa bei der Filterung, übernehmen kann.

Da diese Ansätze eine erhebliche technische wie fachliche Komplexität erfordern, eignet sich auch der Blick auf Ergänzungen, die bereits ohne eine komplette Neuausrichtung zu Verbesserungen führen können. So kann die relative Ortung auch mit deterministischen Verfahren kombiniert werden und hier die möglichen Positionsmengen einschränken, ähnlich der in Kapitel 3.5.1 vorgestellten Predicted k-Nearest Neighbors Filtering. Dieses Vorgehen würde im Grunde eine Verbesserung der bereits implementierten Optimierung „Verwerfen entfernter Messungen“ darstellen und fixierten Positionen entgegenwirken. Auch könnte die Offline-Phase vereinfacht werden, indem statt aller Pfade einzig die Startposition eingezeichnet wird und das Sammeln der Messungen automatisiert geschieht.

Die Ortung mittels Magnetfeldern kann durch den zusätzlich gespeicherten Neigungswinkel präzisiert und als weiteres Unterscheidungsmerkmal damit die häufig zu geringen Signaturunterschiede ausgleichen. Auch das Implementieren weiterer Sensorarten, wie dem Barometer zur Etagenerkennung, dem FM-Radio (falls dies herstellerseitig ermöglicht wird) oder dem Mikrofon, um Umgebungsgeräusche in einem eingeschränkten Frequenzbereich zu sammeln, hat das Potenzial, die Zuverlässigkeit und Genauigkeit der bisherigen Lösung ohne größeren Aufwand nochmals zu erhöhen.

Schließlich stellt die Nutzung semantischer Karten und Modelle einen weiteren Punkt dar, mit dem die aktuelle Anwendung erweitert werden kann. Durch das Anreichern mit Informationen der Umgebung kann, etwa mittels Partikel-Filter, die Ortung verbessert werden, indem unbegehbare Bereiche ausgeschlossen, Ausreißer erkannt oder die Positionen zurückgesetzt werden können. Darüber hinaus könnten jedoch auch gänzlich neue Anwendungsfälle, wie die Indoor-Navigation oder die Unterstützung bei der Gebäudesteuerung durch Gesten, ermöglicht

werden (vgl. etwa [Kar12]).

Es folgt eine kurze Zusammenfassung und das Gesamtfazit dieser Arbeit sowie ein fachlicher Ausblick, in welche Richtung sich das Projekt entwickeln lässt.

## 5 Fazit und Ausblick

Im Laufe der Arbeit wurden Mittel und Wege untersucht, die Positionierung in Innenräumen mit Smartphones zu ermöglichen. Hierzu galt es, zuerst die theoretischen Grundlagen zu erfassen und diese schließlich in einem praktischen Teil auf ihre Umsetzbarkeit und Tauglichkeit hin zu prüfen.

Die Arbeit wurde in Kapitel 1 mit der Motivation zu diesem Thema begonnen. Es wurde die Bedeutung der Position für die Kontexterkenkung erläutert und deren Notwendigkeit für das Ubiquitous Computing, besonders für Smart Homes, hervorgehoben. Proprietäre Systeme sind zwar am Markt vorhanden und zu einer teils außerordentlich genauen Positionierung in Innenräumen geeignet, aber aus Kosten- und Aufwandsgründen für den Privatanutzer nicht interessant. Es galt daher, Möglichkeiten zu finden, die praktisch für jeden Nutzer geeignet und bedienbar sind. Smartphones stellen aufgrund ihrer hohen Verbreitung und der Vielzahl integrierter Sensoren für diesen Zweck nahezu ideale Instrumente dar.

Diese Einschränkung ist nötig, da aufgrund der knappen Platzverhältnisse sowie der Ausrichtung auf Portabilität viele Sensoren gegenüber ihren Äquivalenten im stationären Bereich deutliche Genauigkeits- und Zuverlässigkeitseinbußen aufweisen. Kapitel 2 galt daher der Übersicht und dem Verständnis von in Smartphones integrierten Sensoren sowie ihrer Vor- und Nachteile. Sensoren, die im Hintergrund arbeiten und durch den Verbund für die Ortung mit ausreichender Genauigkeit genutzt werden können, wurden in die Auswahl für den Praxisteil übernommen.

Die Verfahren, die mit den ausgewählten Sensoren für die Positionierung genutzt werden können, waren das Thema in Kapitel 3. Die Struktur erfolgte durch die Unterscheidung zwischen absoluter und relativer Ortung sowie weiterhin der zwischen deterministischen und probabilistischen Ansätzen. Unter anderem wurden die Verfahren Trilateration und Fingerprinting, Sensor-Fusion und einige Filterungsarten besprochen sowie Techniken wie SLAM und Clustering vorgestellt. Schließlich wurde die Kombination aus deterministischem Fingerprinting



und einem speziellen Nearest Neighbor Filter zur Untersuchung ausgewählt und implementiert.

Den Verfahren folgte in Kapitel 4 die Präsentation der für den Test notwendigen Anwendung IndoorGPS, ihrer grundsätzlichen Architektur sowie der Idee, optionale Module zur Verbesserung der Ortung einzubinden. Die Anwendung, und damit die Nutzung der besprochenen Sensoren und Verfahren, wurde daraufhin Praxistests unter Berücksichtigung der Frage nach einer zuverlässigen, raumweiten Lokalisierung unabhängig vom Gebäude unterzogen. Die Versuche ergaben, dass die genutzte Auswahl dies zwar unter Laborbedingungen erreichen konnte, in einem simulierten Praxiseinsatz allerdings zu stark vom erwarteten Ergebnis abwich und damit noch nicht in jedem Fall für die Ortung von Personen geeignet ist. Abgeschlossen wurde das Kapitel daher neben der Ergebnisdiskussion mit einem Ausblick auf die technischen Möglichkeiten zur Verbesserung der Leistung sowie die bereits aktuell denkbaren Einsatzzwecke des Projekts.

Wie mit dem Ubicomp-Bereich bereits angedeutet, ließe sich als Einsatzmöglichkeit innerhalb der nächsten Jahre der Fokus auf die Individualisierung und Kontextualisierung durch allgegenwärtige Assistenten legen. Was mit Smartphones seinen Anfang nahm und uns bereits teilweise ermöglicht, passende kontextbasierte Informationen zu erhalten, wird in naher Zukunft voraussichtlich noch deutlich individueller auf den Nutzer zugeschnitten erfolgen. Erforscht wird dieses Gebiet momentan am Sonderforschungsbereich/Transregio 62<sup>1</sup> unter dem Namen „Companion-Systeme“.

Als Companions werden solche Systeme bezeichnet, die vollständig an den Nutzer angepasst sind und sowohl auf die Situation als auch die emotionale Befindlichkeit Rücksicht nehmen. Die Beachtung der emotionalen Befindlichkeit ist zum Beispiel für schwer kontrollierbare Systeme, wie dem Steuern von Autos oder Ähnlichem in Form von Fahrassistenzsystemen denkbar, die den Nutzer in Stresssituationen zusätzlich adäquat unterstützen. Dies kann sich zum Beispiel durch eine künstliche Geschwindigkeitsbeschränkung oder dem automatischen Eingreifen in die Steuerung des Systems ausdrücken, wobei stets der Anspruch der kompetenten und partnerschaftlichen Dienstleistung im Mittelpunkt steht. Die Erkennung von Emotionen wird darüber hinaus aktuell auch im Rahmen des EmoBike-Projekts[Bie15] im Living Place an der HAW Hamburg erforscht.

---

<sup>1</sup><http://www.sfb-trr-62.de>, Abruf: 06.02.2017

Allerdings ist eine zuverlässige Positionserkennung besonders für die situative Kontextsensitivität in diesem Bereich nützlich. Um Companions entwickeln zu können, ist ein umfangreiches Verständnis des Kontexts nötig, dessen integraler Bestandteil die Lokalisation des Nutzers darstellt. Companions können umso besser abgestimmt werden, je mehr Informationen sie über ihre Umgebung erhalten. Zur Verdeutlichung lassen sich Smartphones heranziehen, die bereits heute desto besser angepasste Dienstleistungen anbieten können, je mehr Wissen über den Nutzer und dessen Umgebung preisgegeben wird. Das Erinnern an einem bestimmten Standort oder das Anzeigen von für den Nutzer interessanten Orten sind Beispiele hierfür.

Neben dem Einfluss auf die Entwicklung von Companions lässt sich noch eine ganze Reihe weiterer Einsatzmöglichkeiten finden, etwa die Unterstützung bei der Automatisierung von Lagerhäusern, indem Lagerroboter bei der Suche nach dem passenden Abschnitt zu ihrem Ziel gelotst werden und sich daraufhin selbstständig nur noch um die feingranularere Koordination kümmern müssen; die Verbesserung von Parkhäusern, bei der Autofahrer zu freien Parkplätzen geführt werden, oder die von Hotelanlagen, sodass in diesen Touristen mit weniger Personal individuell geleitet werden können.

Allerdings laufen all diese Ideen auf eine Erkenntnis hinaus: Für die umfassende Unterstützung durch aktuelle wie zukünftige Software ist eine Positionierung nicht nur sinnvoll, sondern zwingend erforderlich und diese Arbeit dient dabei der Übersicht sowie dem Aufzeigen von Wegen, einem solchen Ziel in umfänglicher Weise näher zu kommen.

# Literaturverzeichnis

- [ACRC09] Martin Azizyan, Ionut Constandache, and Romit Roy Choudhury. SurroundSense: mobile phone localization via ambience fingerprinting. In *Proceedings of the 15th annual international conference on Mobile computing and networking*, pages 261–272. ACM, 2009.
- [AV07] David Arthur and Sergei Vassilvitskii. k-means++: The advantages of careful seeding. In *Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms*, pages 1027–1035. Society for Industrial and Applied Mathematics, 2007.
- [Bar15] Lennart Bartelt. Projektbericht: Indoor Positionierung mittels Sensor Fusion auf Smartphones. 2015.
- [Bar16a] Lennart Bartelt. Indoor Positionierung mit Smartphones zur Kontextererkennung auf Basis vorhandener Infrastruktur. 2016.
- [Bar16b] Lennart Bartelt. Skalierende Indoor Positionierung mit Smartphones zur Kontextererkennung. 2016.
- [Bie15] Kai Bielenberg. Companion Technologie - Eyetracker und Emotionen. 2015.
- [BP00] Paramvir Bahl and Venkata N. Padmanabhan. RADAR: an in-building RF-based user location and tracking system. In *INFOCOM 2000. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Proceedings. IEEE*, volume 2, pages 775–784. IEEE, 2000.
- [BYG<sup>+</sup>15] Sinem Bozkurt, Ahmet Yazıcı, Serkan Gunal, Ugur Yayan, and Fatih Inan. A novel multi-sensor and multi-topological database for indoor positioning on fingerprint techniques. In *Innovations in Intelligent Systems and Applications (INISTA), 2015 International Symposium on*, pages 1–7. IEEE, 2015.

- [CLLP12] Yin Chen, Dimitrios Lymberopoulos, Jie Liu, and Bodhi Priyantha. FM-based indoor localization. In *Proceedings of the 10th international conference on Mobile systems, applications, and services*, pages 169–182. ACM, 2012.
- [CSC<sup>+</sup>16] Nicholas Capurso, Tianyi Song, Wei Cheng, Jiguo Yu, and Xiuzhen Cheng. An Android-based Mechanism for Energy Efficient Localization depending on Indoor/Outdoor Context. *IEEE Internet of Things Journal*, 2016.
- [CZJ<sup>+</sup>15] Zhenghua Chen, Han Zou, Hao Jiang, Qingchang Zhu, Yeng Chai Soh, and Lihua Xie. Fusion of WiFi, Smartphone Sensors and Landmarks Using the Kalman Filter for Indoor Localization. *Sensors*, 15(1):715–732, 2015.
- [DLR77] Arthur P. Dempster, Nan M. Laird, and Donald B. Rubin. Maximum Likelihood from Incomplete Data via the EM Algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)*, pages 1–38, 1977.
- [Dou04] Paul Dourish. What we talk about when we talk about context. *Personal and ubiquitous computing*, 8(1):19–30, 2004.
- [DYY<sup>+</sup>13] Zhongliang Deng, Yanpei Yu, Xie Yuan, Neng Wan, and Lei Yang. Situation and development tendency of indoor positioning. *China Communications*, 10(3):42–55, 2013.
- [EKV<sup>+</sup>11] Jens Ellenberg, Bastian Karstaedt, Sören Voskuhl, Kai von Luck, and Birgit Wendholt. An Environment for Context-Aware Applications in Smart Homes. In *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Guimarães, Portugal, 2011.
- [Elk03] Charles Elkan. Using the Triangle Inequality to Accelerate k-Means. In *ICML*, volume 3, pages 147–153, 2003.
- [ETZ05] Bernd Eissfeller, Andreas Teuber, and Peter Zucker. Indoor-GPS: ist der Satellitenempfang in Gebäuden möglich. *ZfV, Zeitschrift für Vermessung*, (4):130, 2005.
- [FCC13] Viacheslav Filonenko, Charlie Cullen, and James D. Carswell. Indoor Positioning for Smartphones Using Asynchronous Ultrasound Trilateration. *ISPRS International Journal of Geo-Information*, 2(3):598–620, 2013.
- [FH13] Ramsey Faragher and Robert Harle. SmartSLAM – an efficient smartphone indoor positioning system exploiting machine learning and opportunistic sensing. In *ION GNSS*, volume 13, pages 1–14, 2013.

- [FH14] Ramsey Faragher and Robert Harle. An Analysis of the Accuracy of Bluetooth Low Energy for Indoor Positioning Applications. In *Proceedings of the 27th International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS+ '14)*, 2014.
- [FSN12] Ramsey Faragher, Carlos Sarno, and Mark Newman. Opportunistic radio SLAM for indoor navigation using smartphone sensors. In *Position Location and Navigation Symposium (PLANS), 2012 IEEE/ION*, pages 120–128. IEEE, 2012.
- [Gut00] Jens-Steffen Gutmann. *Robuste Navigation autonomer mobiler Systeme*. Aka, 2000.
- [Har13] Robert Harle. A Survey of Indoor Inertial Positioning Systems for Pedestrians. *IEEE Communications Surveys & Tutorials*, 15(3):1281–1293, 2013.
- [HC16] Suining He and S.-H. Gary Chan. Wi-Fi Fingerprint-Based Indoor Positioning: Recent Advances and Comparisons. *IEEE Communications Surveys & Tutorials*, 18(1):466–490, 2016.
- [Heg10] Günther Hegewald. *Die Ganggeschwindigkeit - eine zentrale Größe in der Ganganalyse*, 2010.
- [HJLY14] Dongsoo Han, Sukhoon Jung, Minkyu Lee, and Giwan Yoon. Building a Practical Wi-Fi-Based Indoor Navigation System. *Pervasive Computing, IEEE*, 13(2):72–79, 2014.
- [HK09] Janne Haverinen and Anssi Kemppainen. Global indoor self-localization based on the ambient magnetic field. *Robotics and Autonomous Systems*, 57(10):1028–1035, 2009.
- [HPALP09] Ville Honkavirta, Tommi Perala, Simo Ali-Loytty, and Robert Piché. A comparative survey of WLAN location fingerprinting methods. In *Positioning, Navigation and Communication, 2009. WPNC 2009. 6th Workshop on*, pages 243–251. IEEE, 2009.
- [HS15] A.K.M. Mahtab Hossain and Wee-Seng Soh. A survey of calibration-free indoor positioning systems. *Computer Communications*, 66:1–13, 2015.
- [HZJ<sup>+</sup>14] Chengkai Huang, Gong Zhang, Zhuqing Jiang, Chao Li, Yupeng Wang, and Xueyang Wang. Smartphone-based indoor position and orientation tracking fusing inertial and magnetic sensing. In *Wireless Personal Multimedia Communications (WPMC), 2014 International Symposium on*, pages 215–220. IEEE, 2014.

- [JMF99] Anil K. Jain, M. Narasimha Murty, and Patrick J. Flynn. Data clustering: a review. *ACM computing surveys (CSUR)*, 31(3):264–323, 1999.
- [Kar12] Bastian Karstaedt. Kontextinterpretation in Smart Homes auf Basis semantischer 3D Gebäudemodelle. Master’s thesis, Hochschule für Angewandte Wissenschaften Hamburg, 2012.
- [Kar15] Hassan A. Karimi. *Indoor Wayfinding and Navigation*. CRC Press, 2015.
- [KH15] Wonho Kang and Youngnam Han. SmartPDR: Smartphone-Based Pedestrian Dead Reckoning for Indoor Localization. *Sensors Journal, IEEE*, 15(5):2906–2916, 2015.
- [KJBK15] Manikanta Kotaru, Kiran Joshi, Dinesh Bharadia, and Sachin Katti. SpotFi: Decimeter Level Localization Using WiFi. In *Proceedings of the 2015 ACM Conference on Special Interest Group on Data Communication*, pages 269–282. ACM, 2015.
- [KKB<sup>+</sup>15] Fredrik Karlsson, Martin Karlsson, Bo Bernhardsson, Fredrik Tufvesson, and Magnus Persson. Sensor Fused Indoor Positioning Using Dual Band WiFi Signal Measurements. pages 1669–1672, 2015.
- [KMH10] Shahrzad Khodayari, Mina Maleki, and Elham Hamedi. A RSS-based fingerprinting method for positioning based on historical data. In *Performance Evaluation of Computer and Telecommunication Systems (SPECTS), 2010 International Symposium on*, pages 306–310. IEEE, 2010.
- [KMK16] Pavel Kriz, Filip Maly, and Tomas Kozel. Improving Indoor Localization Using Bluetooth Low Energy Beacons. *Mobile Information Systems*, 2016, 2016.
- [LCJ<sup>+</sup>15] Huaiyu Li, Xiuwan Chen, Guifei Jing, Yuan Wang, Yanfeng Cao, Fei Li, Xinlong Zhang, and Han Xiao. An Indoor Continuous Positioning Algorithm on the Move by Fusing Sensors and Wi-Fi on Smartphones. *Sensors*, 15(12):31244–31267, 2015.
- [LDRZ14] Yang Liu, Marzieh Dashti, Mohd Amiruddin Abd Rahman, and Jie Zhang. Indoor localization using smartphone inertial sensors. In *Positioning, Navigation and Communication (WPNC), 2014 11th Workshop on*, pages 1–6. IEEE, 2014.
- [LGL12] Xiaomei Liang, Xuerong Gou, and Yong Liu. Fingerprint-based location positioning using improved KNN. In *2012 3rd IEEE International Conference on Network Infrastructure and Digital Content*, pages 57–61. IEEE, 2012.

- [LZL<sup>+</sup>16] You Li, Yuan Zhuang, Haiyu Lan, Qifan Zhou, Xiaoji Niu, and Naser El-Sheimy. A Hybrid WiFi/Magnetic Matching/PDR Approach for Indoor Navigation With Smartphone Sensors. *IEEE Communications Letters*, 20(1):169–172, 2016.
- [Mac67] James MacQueen. Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, pages 281–297. Oakland, CA, USA., 1967.
- [MBB14] Juraj Machaj, Peter Brida, and Jozef Benikovsky. Using GSM signals for fingerprint-based indoor positioning system. In *ELEKTRO, 2014*, pages 64–67. IEEE, 2014.
- [MC12] Fionn Murtagh and Pedro Contreras. Algorithms for hierarchical clustering: an overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2(1):86–97, 2012.
- [MGHX15] Rui Ma, Qiang Guo, Changzhen Hu, and Jingfeng Xue. An Improved WiFi Indoor Positioning Algorithm by Weighted Fusion. *Sensors*, 15(9):21824–21843, 2015.
- [MJC<sup>+</sup>15] Xia Mingzhe, Chen Jiabin, Song Chunlei, Li Nan, and Chen Kong. The indoor positioning algorithm research based on improved location fingerprinting. In *The 27th Chinese Control and Decision Conference (2015 CCDC)*, pages 5736–5739. IEEE, 2015.
- [MKM<sup>+</sup>14] Kartik Muralidharan, Azeem Javed Khan, Archan Misra, Rajesh Krishna Balan, and Sharad Agarwal. Barometric phone sensors: more hype than hope! In *Proceedings of the 15th Workshop on Mobile Computing Systems and Applications*, page 12. ACM, 2014.
- [MPS14] Luca Mainetti, Luigi Patrono, and Ilaria Sergi. A survey on indoor positioning systems. In *Software, Telecommunications and Computer Networks (SoftCOM), 2014 22nd International Conference on*, pages 111–120. IEEE, 2014.
- [NRALP13] Henri Nurminen, Anssi Ristimäki, Simo Ali-Löytty, and Robert Piché. Particle filter and smoother for indoor localization. In *Indoor Positioning and Indoor Navigation (IPIN), 2013 International Conference on*, pages 1–10. IEEE, 2013.
- [PK07] Thomas Pintaric and Hannes Kaufmann. Affordable Infrared-Optical Pose-Tracking for Virtual and Augmented Reality. In *Proceedings of Trends and Issues in Tracking for Virtual Environments Workshop, IEEE VR*, pages 44–51, 2007.

- [PMK15] Ramakanth Putta, Manoj Misra, and Divye Kapoor. Smartphone based indoor tracking using magnetic and indoor maps. In *Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP), 2015 IEEE Tenth International Conference on*, pages 1–6. IEEE, 2015.
- [Pos16] Peter Poschmann. Vorlesungsmaterial - Kalman-Filter und Target Tracking. [https://www.htw-dresden.de/fileadmin/userfiles/info\\_math/KogRob/Lehre/MMK/Vorlesung/kalman-filter.pdf](https://www.htw-dresden.de/fileadmin/userfiles/info_math/KogRob/Lehre/MMK/Vorlesung/kalman-filter.pdf), 2016.
- [PZZ<sup>+</sup>16] Ling Pei, Min Zhang, Danping Zou, Ruizhi Chen, and Yuwei Chen. A Survey of Crowd Sensing Opportunistic Signals for Indoor Localization. *Mobile Information Systems*, 2016, 2016.
- [Rah08] Jörg Rahnenführer. Vorlesungsmaterial - Multivariate Verfahren WS0809, 2008.
- [RKT<sup>+</sup>15] Brent A. Renfro, Josh King, Audric Terry, Jeff Kammerman, David Munton, and Johnathan York. An Analysis of Global Positioning System (GPS) Standard Positioning System (SPS) Performance for 2013. 2015.
- [RL00] Maria Isabel Ribeiro and Pedro Lima. Introduction to Kalman Filtering. *Robótica*, 2000.
- [RPL07] Heinrich Ruser and Fernando Puente León. Informationsfusion – Eine Übersicht (Information Fusion – An Overview). *tm-Technisches Messen*, 74(3):93–102, 2007.
- [SBS<sup>+</sup>15] Yuanchao Shu, Cheng Bo, Guobin Shen, Chunshui Zhao, Liqun Li, and Feng Zhao. Magicol: Indoor Localization Using Pervasive Magnetic Field and Opportunistic WiFi Sensing. *Selected Areas in Communications, IEEE Journal on*, 33(7):1443–1457, 2015.
- [Sch13] Georg Schmitz. Vorlesungsmaterial - Kalman-Filter. <https://www.ei.rub.de/media/ei/lehrmaterialien/120/a896a6a0b135530a8a00b094fa631b2ea0e1c95d/KalmanFolien.pdf>, 2013.
- [SCZ<sup>+</sup>15] Xingfa Shen, Yueshen Chen, Jianhui Zhang, Landi Wang, Guojun Dai, and Tian He. BarFi: Barometer-Aided Wi-Fi Floor Localization Using Crowdsourcing. In *Mobile Ad Hoc and Sensor Systems (MASS), 2015 IEEE 12th International Conference on*, pages 416–424. IEEE, 2015.



- [SLLK12] Beomju Shin, Jung Ho Lee, Taikjin Lee, and Hyung Seok Kim. Enhanced weighted K-nearest neighbor algorithm for indoor Wi-Fi positioning systems. In *Computing Technology and Information Management (ICCM), 2012 8th International Conference on*, volume 2, pages 574–577. IEEE, 2012.
- [SZLV14] Kalyan Subbu, Chi Zhang, Jun Luo, and Athanasios Vasilakos. Analysis and status quo of smartphone-based indoor localization systems. *Wireless Communications, IEEE*, 21(4):106–112, 2014.
- [TDA<sup>+</sup>15] Ye Tian, Bruce Denby, Iness Ahriz, Pierre Roussel, and Gérard Dreyfus. Robust indoor localization and tracking using GSM fingerprints. *EURASIP Journal on Wireless Communications and Networking*, 2015(1):1–12, 2015.
- [TDDM11] Stephen P. Tarzia, Peter A. Dinda, Robert P. Dick, and Gokhan Memik. Indoor localization without infrastructure using the acoustic background spectrum. In *Proceedings of the 9th international conference on Mobile systems, applications, and services*, pages 155–168. ACM, 2011.
- [Vap98] Vladimir Naumovich Vapnik. *Statistical learning theory*, volume 1. Wiley New York, 1998.
- [VKK16] Deepak Vasisht, Swarun Kumar, and Dina Katabi. Decimeter-Level Localization with a Single WiFi Access Point. In *13th USENIX Symposium on Networked Systems Design and Implementation (NSDI 16)*, pages 165–178, 2016.
- [Voi09] Tobias Voigt. *Der EM-Algorithmus*. 2009.
- [Vos11] Sören Voskuhl. Modellunabhängige Kontextinterpretation in einer Smart Home Umgebung. *Masterarbeit. Hochschule für Angewandte Wissenschaften Hamburg*, 2011.
- [Wei91] Mark Weiser. The Computer for the 21st Century. *Scientific american*, 265(3):94–104, 1991.
- [Wei02] Harvey Weinberg. Using the ADXL202 in Pedometer and Personal Navigation Applications. *Analog Devices AN-602 application note*, 2(2):1–6, 2002.
- [WSE<sup>+</sup>12] He Wang, Souvik Sen, Ahmed Elgohary, Moustafa Farid, Moustafa Youssef, and Romit Roy Choudhury. No need to war-drive: unsupervised indoor localization. In *Proceedings of the 10th international conference on Mobile systems, applications, and services*, pages 197–210. ACM, 2012.

- [WW72] Wolfgang Wiltschko and Roswitha Wiltschko. Magnetic Compass of European Robins. *Science*, 176(4030):62–64, 1972.
- [XGT<sup>+</sup>14] Hongwei Xie, Tao Gu, Xianping Tao, Haibo Ye, and Jian Lv. MaLoc: a practical magnetic fingerprinting approach to indoor localization using smartphones. In *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pages 243–253. ACM, 2014.
- [XWQ<sup>+</sup>15] Hao Xia, Xiaogang Wang, Yanyou Qiao, Jun Jian, and Yuanfei Chang. Using Multiple Barometers to Detect the Floor Location of Smart Phones with Built-in Barometric Sensors for Indoor Positioning. *Sensors*, 15(4):7857–7877, 2015.
- [XWYN12] Jiang Xiao, Kaishun Wu, Youwen Yi, and Lionel M. Ni. FIFS: Fine-Grained Indoor Fingerprinting System. In *2012 21st International Conference on Computer Communications and Networks (ICCCN)*, pages 1–7. IEEE, 2012.
- [YA05] Moustafa Youssef and Ashok Agrawala. The Horus WLAN location determination system. In *Proceedings of the 3rd international conference on Mobile systems, applications, and services*, pages 205–218. ACM, 2005.
- [YAS03] Moustafa Youssef, Ashok Agrawala, and Udaya Shankar. WLAN location determination via clustering and probability distributions. In *Pervasive Computing and Communications, 2003.(PerCom 2003). Proceedings of the First IEEE International Conference on*, pages 143–150. IEEE, 2003.
- [YS15] Chouchang Yang and Huai-Rong Shao. WiFi-based indoor positioning. *Communications Magazine, IEEE*, 53(3):150–157, 2015.
- [ZXM<sup>+</sup>14] Xiaojie Zhao, Zhuoling Xiao, Andrew Markham, Niki Trigoni, and Yong Ren. Does BTLE measure up against WiFi? A comparison of indoor location performance. In *European Wireless 2014; 20th European Wireless Conference; Proceedings of*, pages 1–6. VDE, 2014.

*Hiermit versichere ich, dass ich die vorliegende Arbeit ohne fremde Hilfe selbständig verfasst und nur die angegebenen Hilfsmittel benutzt habe.*

Hamburg, 14. Februar 2017

---

Lennart Bartelt