

---

# Mobile Multisensorsysteme

Heiner Kuhlmann und Lasse Klingbeil

## Inhaltsverzeichnis

1	Einleitung .....	2
1.1	Problemstellung .....	2
1.2	Systeme und Anwendungen .....	5
2	Trajektorienbestimmung .....	7
2.1	Koordinatensysteme .....	8
2.2	Relative Messverfahren .....	10
2.3	Absolute Messverfahren .....	14
2.4	Filterung und Sensorfusion .....	18
3	Systemkalibrierung .....	27
3.1	Räumliche Kalibrierung .....	27
3.2	Synchronisierung der Sensordaten .....	29
4	Der „Mapping on Demand“ Oktokopter– Ein fliegendes Multisensorsystem .....	30
4.1	Sensoren .....	30
4.2	Synchronisierte Auslese und Verarbeitung der Sensordaten .....	31
4.3	Algorithmen zur Trajektorienbestimmung .....	33
4.4	Ergebnis .....	33
	Literatur .....	34

---

Dieser Beitrag ist Teil des Handbuchs der Geodäsie, Band „Ingenieurgeodäsie“, herausgegeben von Willfried Schwarz, Weimar.

H. Kuhlmann (✉)

Institut für Geodäsie und Geoinformation, Rheinische Friedrich-Wilhelms-Universität Bonn,  
Bonn, Deutschland

E-Mail: [heiner.kuhlmann@uni-bonn.de](mailto:heiner.kuhlmann@uni-bonn.de)

L. Klingbeil

Institut für Geodäsie und Geoinformation, Rheinische Friedrich-Wilhelms-Universität Bonn,  
Bonn, Deutschland

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

## Zusammenfassung

Mobile Multisensorsysteme ermöglichen es, die Umgebung und Objekte darin sehr effizient, das heißt mit geringem Zeitaufwand dreidimensional zu erfassen. Sie enthalten üblicherweise eine Vielzahl von Sensoren, die sowohl zur Berechnung der Trajektorie der bewegten Sensorplattform als auch zur Vermessung der Umgebung eingesetzt werden. Die Aufgaben beim Betrieb von Multisensorsystemen, über die dieses Kapitel einen Überblick gibt, sind die zeitliche Synchronisierung sowie die räumliche Zuordnung aller Sensordaten und die Berechnung der Position und Orientierung der Plattform in einem übergeordneten Koordinatensystem zu jedem Zeitpunkt.

## Schlüsselwörter:

Laserscanner • Inertialnavigation • Kalman-Filter • direkte/indirekte Georeferenzierung • Punktwolke • Mobile-Mapping • Multisensorsystem


# 1 Einleitung

## 1.1 Problemstellung

Die Grundidee bei der Anwendung mobiler Multisensorsysteme ist die Vermessung der Umgebung mit Hilfe von Sensoren, die sich auf einer bewegten Plattform befinden (Abb. 1). „Vermessung der Umgebung“ bedeutet dabei zunächst sehr allgemein die Generierung räumlich aufgelöster Informationen über die Umgebung oder Objekte darin. Die Art der Information wird dabei von der Art des Sensors bestimmt, der auf der mobilen Sensorplattform befestigt ist.

Mit einem Laserscanner lassen sich zum Beispiel Winkel und Abstände zu Objekten der Umgebung messen, um daraus z. B. dreidimensionale Modelle zu generieren (siehe Handbuch der Geodäsie: [Flächenhafte Abtastung mit Laserscanning: Messtechnik, flächenhafte Modellierungen und aktuelle Entwicklungen im Bereich des terrestrischen Laserscannings](#)). Mit Kameras und entsprechenden

**Abb. 1** Ein bewegtes Multisensorsystem nimmt während der Bewegung Daten über die Umgebung oder Objekte darin auf



photogrammetrischen Methoden ist das ebenfalls möglich, wobei hier zusätzlich noch radiometrische Informationen über den Zustand der Objekte erfasst werden können (z. B. Farbe oder Reflektivität des Sonnenlichts bei verschiedenen Wellenlängen). Andere Sensoren ermöglichen die räumlich aufgelöste Erfassung des Schwerfeldes, der Temperatur oder des Luftdrucks.

In allen Fällen ist es notwendig, dass zu den Zeitpunkten der Messung Position und Orientierung des jeweiligen Sensors bekannt sind. Nur so können die Messungen, die im Koordinatensystem des Sensors aufgenommen werden, in das übergeordnete globale Koordinatensystem überführt werden, in dem die Informationen letztendlich gesammelt und dargestellt werden sollen (Abschn. 2.1). Die bewegte Plattform muss also zusätzlich zu den Sensoren zur Beobachtung des Objektraumes weitere Sensoren zur Bestimmung der Trajektorie der Plattform enthalten, wobei die Trajektorie hier die Position und die Orientierung umfasst. Der Name „Multisensorsystem“ trägt vermutlich nicht zufällig dieser Notwendigkeit Rechnung.<sup>1</sup> Der englische Begriff „Mobile-Mapping“, der sich auch im deutschsprachigen Raum durchgesetzt hat, beschreibt den Einsatz eines mobilen Multisensorsystems im oben dargestellten Sinn, allerdings beschränkt er sich dabei bisher auf die geometrische Erfassung mit Kameras oder Laserscannern. Da die „Kartierung“ (Mapping) aber prinzipiell auch die ortsbezogene Erfassung nicht-geometrischer Parameter sein kann, werden die Begriffe „Mobiles Multisensorsystem“ und „Mobile-Mapping-System“ hier äquivalent verwendet.

Ein idealisiertes Beispiel für ein mobiles Multisensorsystem ist in Abb. 2 dargestellt. Die bewegte Plattform enthält einen Laserscanner, der im Profilmodus betrieben wird und in schneller Abfolge Distanzmessungen durchführt, die durch die Bewegung der Plattform die Umgebung spiralförmig abscannen. Weiterhin enthält die Plattform einen Sensor zur Trajektorienbestimmung. Dieser liefert zu jedem Zeitpunkt  $t_s$ , an dem der Laserscanner eine Distanzmessung durchführt, die Position und Orientierung der Plattform im übergeordneten Koordinatensystem der Umgebung  $T_b^g(t_s)$ .


Bestimmt der Laserscanner also über Distanz- und Winkelmessung einen Punkt  $p_s$  in seinem lokalen Koordinatensystem, kann dieser mit Hilfe der Trajektorieninformation in das globale Koordinatensystem der Umgebung transformiert werden, wenn zusätzlich die Transformation  $T_s^b$  zwischen dem Sensorkoordinatensystem und dem Plattformkoordinatensystem bekannt ist:

$$p^g = T_b^g(t_s)T_s^b p^s \quad (1)$$

Obwohl dieses idealisierte Beispiel scheinbar aktuellen kommerziell erhältlichen mobilen Multisensorsystemen entspricht, ist eben genau dieser eine Sensor, der die Position und Orientierung der Plattform zu beliebigen Zeitpunkten bestimmt, die

---

<sup>1</sup> Wie später erläutert wird, lässt sich die Bestimmung der Trajektorie unter gewissen Umständen auch mit Hilfe der Objektraumsensoren bestimmen, so dass prinzipiell ein Multisensorsystem mit nur einem Sensor, z. B. einem Laserscanner oder einer Kamera, denkbar ist.



**Abb. 2** Idealisertes mobiles Multisensorsystem bestehend aus einem Profillaserscanner und einem Sensor zur Trajektorienbestimmung

größte Herausforderung. Um eine möglichst hohe Genauigkeit und Zuverlässigkeit bei unterschiedlichen Plattformeigenschaften und Umgebungsbedingungen zu ermöglichen, werden dazu die Daten vieler verschiedener Sensoren mit entsprechenden Algorithmen zusammengeführt.

Die Problemstellung beim Einsatz von mobilen Multisensorsystemen besteht also aus den folgenden Elementen:

- Feststellung des räumlichen Bezugs der Sensoren zueinander (Rotation und Translation)
- Bestimmung einer gemeinsamen Zeitbasis aller Sensoren
- Bestimmung der Plattformtrajektorie

Zunächst wird ein Überblick über die Entwicklung von mobilen Multisensorsystemen und deren Anwendungen gegeben. Danach werden verschiedene Sensoren und Verfahren zur Trajektorienbestimmung vorgestellt. Anschließend werden Aspekte der Realisierung von Multisensorsystemen, wie der Systemaufbau, die Datensynchronisation und die Feststellung der räumlichen Orientierung der Sensoren zueinander, diskutiert. Am Schluss werden diese Themenbereiche am Beispiel eines fliegenden Multisensorsystems illustriert.

Dieses Kapitel soll lediglich einen Überblick über das sehr ergiebige und komplexe Thema geben. Es werden verschiedene Konzepte und deren Zusammenhang vorgestellt, wobei an den entsprechenden Stellen auf tiefere Literatur verwiesen wird.

## 1.2 Systeme und Anwendungen

Die wohl klassischsten Mobile-Mapping Systeme sind luftgebundene Systeme aus dem Bereich der Luftbildvermessung und der Fernerkundung [1]. Üblicherweise werden hier die Daten von Sensoren zur Erfassung elektromagnetischer Strahlung (Kameras, Spektrometer) mit Hilfe der bekannten Positionen und Orientierung eben dieser Sensoren zu Karten zusammengefasst. Wird die Bewegung der Sensoren dabei mit Hilfe von extra dafür vorhandenen Sensoren (z. B. GNSS und Inertialsensoren, siehe Abschn. 2.4) erfasst, so spricht man von direkter Georeferenzierung. Bei der indirekten Georeferenzierung werden im Gegensatz dazu die aufgenommenen Bilder und darin erkennbare Passpunkte bekannter Position verwendet, um die Trajektorie des Sensorsystems bzw. der Kamera und somit den Raumbezug der erzeugten Karte zu bestimmen (Abschn. 2.3.3). Die Ergebnisse solcher Befliegungen sind z. B. digitale Geländemodelle, Orthophotos oder Vegetationskarten. Eine Verarbeitung der Daten des Multisensorsystems, das bedeutet auch die Bestimmung der Plattformtrajektorie, geschieht üblicherweise nachträglich im Postprocessing. Wie später in Abschn. 4 gezeigt wird, gibt es jedoch Anwendungen, in denen eine Echtzeitberechnung der Trajektorie notwendig ist.

Seit Anfang der 90er-Jahre beschäftigen sich verschiedene Arbeitsgruppen mit der Entwicklung von fahrzeuggebundenen mobilen Multisensorsystemen. Am Institut für Geodäsie der Universität der Bundeswehr wurde das Multisensorsystem KiSS (Kinematic Survey System) entwickelt, welches bei Geschwindigkeiten bis zu 70 km/h mit zwei Kameras den gesamten Verkehrskorridor erfassen konnte [2]. Aufbauend auf diesem System wurde am selben Institut das System MoSES (Mobiles Straßen-Erfassungs-System) entwickelt [3], welches neben Kameras auch Laserscanner enthielt und ebenfalls zur Überwachung des Straßenraumes eingesetzt wurde. Das GEOMOBIL des Institut Cartografie de Catalunya, welches aufbauend auf den Arbeiten von KiSS und MoSES entwickelt wurde, besteht ebenfalls aus einer Kombination von Kameras und Laserscannern [4]. Das VISAT System wurde an der Universität Calgary entwickelt und erfasst die Umgebung mit 8 Kameras bis zu 35 m vom Fahrzeug entfernt bei Geschwindigkeiten bis 60 km/h und erreicht dabei eine Genauigkeit<sup>2</sup> von etwa 30 cm [5]. Als Spezialsysteme für die Erfassung von Fahrbahnoberfläche und -achse sowie der Fahrbahnmarkierung wurden am Institute of Geomatics an der EPFL [6] und an der Ohio State University [7] mobile Multisensorsysteme mit Kameras als Objektraumsensoren entwickelt.

Diese Forschungsarbeiten wurden in den darauf folgenden Jahren erfolgreich zu kommerziellen Anwendungen und Systemen weiterentwickelt. Ab dem Jahr 2010 gab es einen regelrechten Boom für Mobile-Mapping-Systeme, in dem zahlreiche neue Firmen entstanden oder bestehende Firmen solche Systeme in ihr Portfolio aufnahmen. Eine guter Überblick darüber ist in Puente et al. [8] gegeben. Die kommerziell erhältlichen Systeme enthalten meist eine sehr hochwertige Inertial-

---

<sup>2</sup> In diesem Kapitel wird mit Genauigkeit generell die Abweichung der Messung oder Schätzung vom wahren Wert bezeichnet, ohne die Komplexität bei der Bestimmung und Beschreibung von Genauigkeiten zu berücksichtigen.

sensoreinheit, ein oder zwei GNSS-Empfänger, einen oder mehrere Laserscanner sowie Kameras. Die Laserscanner sind dabei üblicherweise Profils Scanner, die für hohe Scanraten optimiert sind, um die Profildichte bei hohen Geschwindigkeiten möglichst hoch zu halten. Einen Überblick über aktuelle Scanner in mobilen Anwendungen findet sich in Klingbeil et al. [9]. Die Bestimmung der Trajektorien geschieht üblicherweise im Nachhinein mit Hilfe der GNSS-Empfänger und der Inertialsensoren als direkte Georeferenzierung. In seltenen Fällen wird die Georeferenzierung der Daten durch Passpunkte verbessert.

Zur Untersuchung der Wasserwege über und unter Wasser werden auch Schiffe als Multisensorsysteme eingesetzt [10]. Über Wasser kommen hier wie bei den oben genannten Fahrzeugen Profil-Laserscanner zum Einsatz, unter Wasser lässt sich die Fahrrinne mit Hilfe eines Fächerecholots dreidimensional erfassen. Zusätzlich zu der schon erwähnten Kombination aus GNSS-Empfängern und Inertialsensoren kommen hier zur Trajektorienbestimmung noch andere Sensoren, wie das Dopplerlog oder Windmesser zum Einsatz.

Interessante neue Herausforderungen ergeben sich durch die Übertragung der Technologie auf andere Trägerplattformen, wie z. B. den Menschen selbst oder leichte unbemannten Flugobjekte (Unmanned Aerial Vehicles, UAVs). Diese Plattformen zeichnen sich dadurch aus, dass sie das Gewicht und die Größe der einsetzbaren Sensoren limitieren und die erprobten kommerziell erhältlichen, aber großen und schweren GNSS/IMU Systeme meist keine Option sind. Die in diesen Fällen eingesetzten leichteren und kleineren Inertialsensoreinheiten sind aber weniger genau und weisen bereits nach sehr kurzen Zeiten hohe Abweichungen auf (Abschn. 2.2.1). Das wiederum führt zu besonderen Herausforderungen bei der Berechnung der Trajektorien und verlangt unter Umständen die Einbindung weiterer Sensormodalitäten (Abschn. 2.4), insbesondere wenn z. B. in der Nähe oder innerhalb eines Gebäudes keine zufriedenstellenden GNSS-Beobachtungen zur Verfügung stehen.

Weitere Herausforderungen ergeben sich bei Bedarf nach einer direkten Georeferenzierung der Daten in Echtzeit, das heißt wenn die Ergebnisse der Positions- und Orientierungsbestimmung zur autonomen Navigation der Plattform verwendet werden sollen und wenn die Ergebnisse des Mapping-Vorgangs bereits während der Fahrt oder des Fluges zur Verfügung stehen müssen. Beispiele dafür sind Absteckungsanwendungen, wie z. B. die Baumaschinensteuerung oder die koordinatengesteuerte Rübenaussaat [11]. In beiden Beispielen ist es notwendig, aus der Bewegung heraus, zum Zeitpunkt der Erreichung einer vorher definierten Position bzw. Orientierung, eine Aktion auszuführen. Andere Beispiele für die Echtzeitanwendungen sind die Unterstützung der Entscheidungsfindung in Katastrophenfällen durch Beobachtungen aus der Luft oder die sog. Exploration, eine Disziplin der mobilen Robotik, in der ein autonomes System aufbauend auf bisherigen Kartierungsergebnissen eine hinsichtlich verschiedener Zielparameter (z. B. Vollständigkeit und Genauigkeit) optimale Kartierung vornimmt [12].

## 2 Trajektorienbestimmung

Die Bestimmung der Plattformtrajektorie ist das zentrale Element eines Mobile-Mapping-Systems. Dazu gibt es zahlreiche Sensoren, Messverfahren und Auswertemethoden, über die im Folgenden ein Überblick gegeben werden soll. Das Ziel der Trajektorienbestimmung ist die Bestimmung aller sechs Freiheitsgrade der Bewegung der Plattform, also die Position und Rotation bezogen auf ein übergeordnetes globales Koordinatensystem, und zwar zu jedem Zeitpunkt. Je nach Anwendung und Messverfahren kann die Auswertung der dafür erfassten Sensordaten entweder in Echtzeit oder im Postprocessing geschehen.


Die Messverfahren lassen sich außerdem in relative und absolute Verfahren unterteilen. Bei relativen Verfahren werden nur Änderungen von Positionen, Strecken oder Rotationen erfasst, so dass der absolute Bezug nicht bekannt ist. Das hat die Nachteile, dass zum einen für eine absolute Bestimmung die absolute Position und Orientierung der Plattform zu irgendeinem Zeitpunkt in der Vergangenheit bekannt gewesen sein musste (Initialisierung) und zum anderen, dass die Unsicherheit dieser absoluten Bestimmung mit der Zeit wächst. Im Gegensatz dazu können mit absoluten Verfahren die absolute Position oder Rotation direkt bestimmt werden. Die Kombination verschiedener absoluter und relativer Verfahren mit Hilfe von Filteralgorithmen, wie z. B. dem Kalman-Filter (Abschn. 2.4.1) entspricht dem Stand, der heutzutage in den meisten mobilen Multisensorsystemen zum Einsatz kommt.

Eine weitere Möglichkeit zur Unterteilung der Verfahren ist die in direkte und indirekte Verfahren. Diese Bezeichnung wird hier im Sinne der Begriffe „direkte“ und „indirekte“ Georeferenzierung verwendet. Die Berechnung der Trajektorie mit Hilfe von zu diesem Zweck am Sensorsystem befestigten Inertialsensoren und GNSS-Empfängern wird hier als direktes Verfahren bezeichnet. Im Gegensatz dazu wird bei indirekten Verfahren die Bestimmung der Trajektorie mit Hilfe der Objektraumsensoren (z. B. Kamera oder Laserscanner) durchgeführt. Das geschieht, wie zum Beispiel bei der Bündelausgleichung in der klassischen Luftbildphotogrammetrie, meist in einem zeitaufwändigen Postprocessing-Schritt und erfordert häufig eine vorherige Manipulation der Umgebung, wie z. B. die Ausbringung von Passpunkten. In letzter Zeit ist jedoch durch Fortschritte in der Verarbeitung von Bildern und Punktwolken sowie durch die immer stärker werdende verfügbare Rechenleistung, die Einbindung von Objektraumbeobachtungen in die Trajektorienbestimmung auch in Echtzeit möglich geworden. Diese im Bereich der mobilen Robotik schon weit verbreiteten Verfahren erhalten immer mehr Einzug in die Trajektorienbestimmung mobiler Multisensorsysteme, insbesondere wenn die Anwendungs- oder Umgebungsbedingungen die Verfügbarkeit von GNSS-Beobachtungen verringern. Tab. 1 zeigt eine mögliche Kategorisierung der verschiedenen Messverfahren zur Trajektorienbestimmung. Die relativen Verfahren beobachten im Vergleich zu absoluten Verfahren lediglich Bewegungsänderungen. Indirekte Verfahren basieren auf Objektraumbeobachtungen durch Kameras oder Laserscanner, wobei die hier aufgelisteten Verfahren teilweise auf ähnlichen oder identischen Methoden basieren, worauf später genauer eingegangen wird.

**Tab. 1** Mögliche Kategorisierung verschiedener Verfahren zur Trajektorienbestimmung

	Direkte Verfahren	Indirekte Verfahren
Relative Verfahren	Inertialnavigation Koppelortung Odometrie GNSS-Geschwindigkeiten	Scan-Matching (Laser) Visuelle Odometrie (Kamera)
Absolute Verfahren	GNSS Neigungssensorik Kompass	Passpunkte/Landmarken (Laser, Kamera) Bündelausgleichung (Kamera) SLAM (Laser, Kamera) Map-Matching (Laser, Kamera, Trajektorie)

**Abb. 3** Verschiedene Koordinatensysteme, die bei der Trajektorienbestimmung für sich bewegende Systeme eine Rolle spielen



## 2.1 Koordinatensysteme

Das Ziel beim Einsatz mobiler Multisensorsysteme ist die Darstellung von in einem mit der Plattform bewegten Sensorkoordinatensystem aufgenommenen Beobachtungen oder daraus abgeleiteter Größen in einem Zielkoordinatensystem (Abb. 3). Das Zielkoordinatensystem wird dabei abhängig von der Anwendung gewählt. Die Transformation zwischen dem Sensorkoordinatensystem und dem Zielkoordinatensystem geschieht im Allgemeinen über mehrere Einzeltransformationen, die teilweise einmalig (Kalibrierung) und teilweise ständig (Trajektorienbestimmung) bestimmt werden müssen.

Inertialsensoren messen die Bewegungsänderungen des Sensorsystems relativ zum Inertialsystem, wohingegen das Zielkoordinatensystem meist ein erdfestes System ist. In diesem Fall (Abschn. 2.2.1) ist der Umgang mit einer Reihe von Koordinatensystemen notwendig, die im Folgenden vorgestellt werden.



Im Falle lokaler Zielkoordinatensysteme (z. B. Baustellensysteme) und ohne die Verwendung von Inertialsensoren würde sich die Zahl der notwendigen Koordinatensysteme verringern.

### Sensorkoordinatensystem (s)

Jeder Sensor hat sein eigenes Koordinatensystem, in dem seine Beobachtungen angegeben sind. Bei einem Profil-Laserscanner sind das z. B. Abstand und Winkel zum Objektpunkt in der Rotationsebene des Spiegels, bei einer Kamera das Kamerakoordinatensystem oder das Bildkoordinatensystem.

### Körperfestes System oder Plattformsystem (b)

Die Achsen des körperfesten Systems liegen fest in der mobilen Plattform: Der Ursprung ist meist der Schwerpunkt oder ein physikalisch anmessbarer Punkt. Die x-Achse zeigt üblicherweise nach vorne, die y-Achse nach links und die z-Achse nach oben.<sup>3</sup> Wichtig ist es, die Transformationen  $T_s^b$  zwischen den einzelnen Sensorkoordinatensystemen und dem körperfesten System (b) zu kennen. Letzteres wird durch Kalibrierverfahren erreicht (Abschn. 3.1).

### Navigationssystem (n)

Das Navigationssystem hat denselben Ursprung wie das körperfeste System. Die x- und y-Achse liegen jedoch tangential am Rotationsellipsoid. Dabei zeigt die x-Achse nach Osten, die y-Achse nach Norden und die z-Achse antiparallel zur Schwerebeschleunigung nach oben (ENU-Konvention: „East-North-Up“).<sup>4</sup> Die Orientierung des Multisensorsystems wird üblicherweise als Rotation  $C_b^n$  zwischen dem Plattformsystem und dem Navigationssystem angegeben.

### Erdfestes System (e)

Das erdfeste System ist häufig das Zielkoordinatensystem für Mobile-Mapping-Anwendungen. Hier gibt es verschiedene Definitionsmöglichkeiten. In diesem Beispiel hat es seinen Ursprung im Mittelpunkt des Rotationsellipsoids. Die Achsen sind fest im Bezug zur Erde. Dabei ist die z-Achse entlang der Rotationsachse, die x-Achse ist die Schnittgerade aus der Äquatorebene und dem Nullmeridian und die y-Achse vervollständigt das Rechtssystem. Die x- und y-Achsen liegen in der Äquatorebene. Als Position  $p_b^e$  des Multisensorsystems wird üblicherweise die Position des Ursprungs des Plattformsystems im erdfesten System angegeben. Welcher Koordinatentyp letztendlich für die Angabe der Position gewählt wird, ist abhängig von der Anwendung.

### Inertialsystem (i)

Der Ursprung und die z-Achse des Inertialsystems sind die gleichen wie im erdfesten System. Die x- und y-Achse liegen in der Äquatorebene. Das erdfeste System rotiert bezüglich des Inertialsystems um seine z-Achse mit der Rotationsgeschwindigkeit  $\omega_{ie}$ . Das Inertialsystem spielt beim Einsatz von Inertialsensoren eine Rolle.

<sup>3</sup> Das entspricht der üblichen Konvention für Landfahrzeuge. Bei fliegenden Systemen zeigt die y-Achse meist nach rechts und die z-Achse nach unten.

<sup>4</sup> Das ist konsistent mit der Definition des körperfesten Systems. Bei Luftfahrzeugen zeigt x nach Norden, y nach Osten und z nach unten (NED: „North-East-Down“).

## 2.2 Relative Messverfahren

### 2.2.1 Inertialnavigation

Die Inertialnavigation ist ein umfangreiches Thema, über das hier ein kurzer Überblick gegeben wird. Detaillierte Informationen über die Sensoren und Algorithmen finden sich z. B. in Titterton & Weston [13] oder in Wendel [14]. Drehratensensoren (Gyroskope) und Beschleunigungssensoren (Akzelerometer) werden als Inertialsensoren bezeichnet. Jeweils drei von Ihnen – eine für jede Raumrichtung – bilden zusammengesetzt eine Inertialsensoreinheit (IMU: Inertial Measurement Unit).

Ausgehend von bekannten Startwerten für die Orientierung, die Position und die Geschwindigkeit lässt sich prinzipiell über zweifache Integration der gemessenen Beschleunigungswerte und einfache Integration der gemessenen Drehraten die absolute Trajektorie eines Objektes rekursiv berechnen:

$$[p_b^e, v_{eb}^e, C_b^n]_k = f([p_b^e, v_{eb}^e, C_b^n]_{k-1}, \omega_{ib}^b, a_{ib}^b) \tag{2}$$

Der Algorithmus, der sich hinter der Funktion  $f$  verbirgt, wird Strapdown-Algorithmus genannt. Dieser ist in (Abb. 4) schematisch dargestellt und wird im Folgenden zusammen mit der Beschreibung der Sensoren und ihrer Eigenschaften beschrieben.

### Drehratensensoren

Drehratensensoren messen die Drehrate  $\omega_{ib}^b$  des Plattformsystems relativ zum Inertialsystem, ausgedrückt im Plattformsystem (hier wird angenommen, dass die Transformation zwischen dem Sensorkoordinatensystem und dem Plattformkoordinatensystem durch Kalibrierung bekannt ist). Die gemessene Drehrate setzt sich allerdings aus mehreren Komponenten zusammen. Neben der Drehrate  $\omega_{nb}^b$ , die

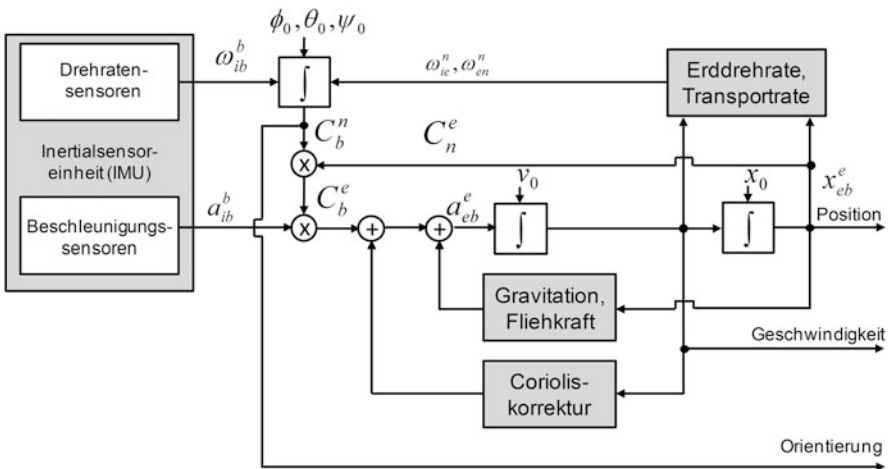


Abb. 4 Schematische Darstellung des Strapdown-Algorithmus

durch Integration zur eigentlich gesuchten Orientierung führt, enthält sie ebenfalls die Erddrehrate  $\omega_{ie}^b$ , sowie die Drehrate  $\omega_{en}^b$  des Navigationssystems relativ zum erdfesten System (Transportrate). Im Strapdown-Algorithmus werden diese Komponenten berücksichtigt, wobei dafür die absolute Orientierung, die Position und die Geschwindigkeit bekannt sein müssen. Der Algorithmus muss also zwingend mit absoluten Startwerten initialisiert werden (Abb. 4). Es ist offensichtlich, dass die Unsicherheit bei dieser Orientierungsbestimmung mit der Zeit wächst und dass systematische Messwertabweichungen sich über die Zeit aufaddieren (Drift). Um die Abweichung der Orientierungsbestimmung möglichst lange klein zu halten, muss man die Abweichungen des Sensors verstehen und minimieren. Hochpreisige Drehratensensoren, die auf optischen Verfahren basieren (Ringlaserkreisel, faseroptischer Kreisel), werden seit Jahrzehnten hauptsächlich in militärischen Anwendungen eingesetzt und ermöglichen eine Winkelgenauigkeit im Bereich von wenigen Grad über mehrere Stunden [13]. Aktuellere Gyroskope auf Basis der MEMS-Technologie (MEMS = Micro-Electro-Mechanical Systems) befinden sich mittlerweile in jedem Smartphone, sind wenige Quadratmillimeter groß und kosten Cent-Beträge. Ihr Einsatz in Navigationsanwendungen ist allerdings wegen der hohen Messwertabweichungen problematisch. Als Beispiel sei hier die Biasstabilität erwähnt, die bei diesen kleinen und günstigen Sensoren klein ist, da das Bias, also der Ausgabewert des Sensors bei Ruhelage, sich mit der Zeit und mit der Temperatur ändert, so dass die Winkelabweichung nach einigen Sekunden bereits mehrere Grad betragen kann. Das Rauschen der Sensoren ist zudem so hoch, dass z. B. die Erddrehrate gar nicht beobachtet werden kann [15]. Dennoch wird die Technologie ständig weiterentwickelt und die Sensoren werden immer besser, so dass hochwertige MEMS-Gyroskope bereits ähnliche Ergebnisse wie günstigere Ringlaser- oder faseroptische Kreisel liefern.

### Beschleunigungssensoren


Beschleunigungssensoren messen die Beschleunigung  $\mathbf{a}_{ib}^b$  des Plattformsystems relativ zum Inertialsystem, ausgedrückt im Plattformsystem (auch hier wird angenommen, dass die Transformation zwischen dem Sensorkoordinatensystem und dem Plattformkoordinatensystem durch Kalibrierung bekannt ist). Zur Positionsbestimmung ist man eigentlich nur an der Beschleunigungskomponente interessiert, die sich aus der Geschwindigkeitsänderung der Plattform bezüglich des erdfesten Systems ergibt. Allerdings misst der Sensor zusätzlich eine Komponente durch die Corioliskraft, welche von der Erddrehrate, der Transportrate und der Geschwindigkeit abhängt, sowie eine Komponente durch die Gravitation und die Fliehkraft (Erdschwere). Diese Komponenten werden im Strapdown-Algorithmus berücksichtigt, allerdings wird dafür zusätzlich zu den eben genannten Abhängigkeiten noch die mit Hilfe der Drehratensensoren bestimmte absolute Orientierung der Plattform benötigt. Mit der Zeit größer werdende Abweichungen in der Orientierungsbestimmung koppeln also daher über eine fehlerhafte Kompensation der ungewollten Beschleunigungskomponenten in die Geschwindigkeits- bzw. Positionsbestimmung ein. Der bei Weitem größte Anteil kommt dabei durch die Erdschwere zustande. Eine Orientierungsabweichung von einem Grad führt

z. B. zu einem Beschleunigungsbias von etwa  $0,2\text{ m/s}^2$ , was wiederum aus der Ruhelage heraus nach einer Sekunde zu einer Positionsabweichung von  $0,2\text{ m}$  führt, die mit der Zeit noch quadratisch ansteigt. Die Qualität der Drehratensensoren spielt daher für die Positionsbestimmung eine mindestens so wichtige Rolle wie die Qualität der Beschleunigungssensoren selbst. Abweichungen wirken sich jedoch in beiden Fällen durch die zweifache Integration besonders schnell aus. Während eine hochpreisige auf optischen Kreiseln basierende IMU in der Lage ist, die Position nach mehreren Minuten noch mit Abweichungen unterhalb eines Meters zu bestimmen, werden mit einer günstigen MEMS-basierten IMU bereits nach Sekunden Abweichungen von mehreren Metern erreicht. Dennoch ist letztere in kosten- und größenlimitierten Systemen häufig die einzige Option, weshalb dort die Auswertelgorithmen und die Einbindung anderer Sensoren zur Stützung der Berechnung eine große Rolle spielen.

### 2.2.2 Koppelortung

Der ursprünglich aus der Schifffahrt kommende Begriff der Koppelortung (engl.: Dead Reckoning) bezeichnet die fortlaufende Bestimmung der eigenen Trajektorie aus Streckenstücken  $s$  und Richtungsänderungen  $\Delta\varphi$  unter der Annahme bekannter Anfangsbedingungen (polares Anhängen, Abb. 5):

$$\begin{aligned}\varphi_k &= \varphi_{k-1} + \Delta\varphi_k \\ x_k &= x_{k-1} + s_i \cos \varphi_k \\ y_k &= y_{k-1} + s_i \sin \varphi_k\end{aligned}\quad (3)$$



**Abb. 5** Prinzip der Koppelortung


Die Streckenstücke können dabei z. B. durch die Zählung von Radumdrehungen mit Radencodern direkt gemessen oder über Geschwindigkeitsmessungen und Zeitinformatonen bestimmt werden. Die Richtungsänderung kann z. B. mit Hilfe von senkrecht zur Trajektorienebene messenden Drehratensensoren oder mit Differentialodometern bestimmt werden. Häufig wird die Richtungsinformation auch direkt mit Hilfe eines absoluten Verfahrens (Abschn. 2.3.2) bestimmt. Die Unsicherheit der Position, die wie in Abb. 5 dargestellt mit der Zeit ungebunden anwächst, hätte in diesem Fall jedoch eine kleinere Komponente senkrecht zur Bewegungsrichtung.

Die Koppelortung wird auch als Odometrie bezeichnet, da für die Messung der zurückgelegten Streckenstücke meist Odometer eingesetzt werden. Odometrie kann auch mit bildbasierten Verfahren durchgeführt werden.

**2.2.3 Visuelle Odometrie**

Bei der visuellen Odometrie wird aus aufeinander folgenden Bildern die Orientierungs- und Positionsänderung der Kamera zwischen zwei Aufnahmezeitpunkten berechnet. Das geschieht, wie in Abb. 6 rechts dargestellt, üblicherweise über korrespondierende Punkte in den Bildern, die mit Hilfe verschiedener Merkmale zugeordnet werden (z. B. SIFT, siehe Lowe [16]). Eine ausführliche Beschreibung dieser Methode findet sich z. B. in Scaramuzza & Fraundorfer [17]).

Erst in den letzten Jahren ist es durch Entwicklungen im Bereich der Bildverarbeitung und durch die immer höher werdende verfügbare Rechenleistung möglich geworden, die visuelle Odometrie in Echtzeit einzusetzen. Verbessert wird die Leistung der Verfahren noch durch die gleichzeitige Verwendung von zwei (Stereo) oder mehr (Multiview-Stereo) Kameras. Die Verfügbarkeit und die Qualität der Bewegungsbestimmung hängen von der Anzahl, der Verteilung und der Erkennbarkeit signifikanter Punkte im Bild ab. Diese wiederum hängen von der Geschwindigkeit der Plattform, der Beschaffung der Umgebung und den Beleuchtungsbedingungen ab. Eine durchgehende Schätzung der Trajektorie ist also nur bei ununterbrochen guten Bedingungen möglich, weshalb die Verwendung zusätzlicher Sensoren ratsam ist.



**Abb. 6** Links: Scan-Matching; Rechts: Visuelle Odometrie

### 2.2.4 ScanMatching

Das sog. Scan-Matching ist ähnlich dem Verfahren der visuellen Odometrie, gearbeitet wird jedoch auf mit einem Laserscanner aufgenommenen Punktwolken. In die Berechnung der relativen Sensorbewegung gehen entweder die Scanpunkte direkt oder aus der Umgebung mehrerer Scanpunkte berechnete Merkmale ein. Ein häufig verwendeter Algorithmus, der die Scanpunkte direkt verwendet, ist der ICP-Algorithmus (ICP = Iterative Closest Points, Besl & McKay [18]). Scan-Matching ist somit ebenfalls ein relatives Verfahren, das im Bereich der mobilen Robotik häufig eine große Rolle spielt. Eine detaillierte Beschreibung dieser Methode findet sich in Lu & Miliotis [19].

### 2.2.5 SLAM

Sowohl bei der visuellen Odometrie als auch beim Scan-Matching treten Drifteffekte auf, die die Abweichung der Trajektorie genau wie bei der Koppelortung und der Inertialnavigation ungebunden wachsen lassen. Hier gibt es allerdings Methoden, diese Drift zu verringern, bzw. zu eliminieren. Wenn man sich die markanten Punkte im Bildraum, die im simplen Fall nur für die Bewegungsschätzung zwischen zwei Aufnahmezeitpunkten verwendet werden, als Punkte im Objektraum merkt, deren Positionsschätzung mit jeder Epoche verbessert und ständig neue Punkte hinzunimmt, so ist zu erwarten, dass sich die Drift signifikant verringert. Wenn man jetzt nach einiger Zeit einen vorher generierten Punkt des Objektraumes wieder sieht, lässt sich durch diesen Schleifenschluss die Drift sogar rückwirkend eliminieren. Mit diesem Verfahren wird also gleichzeitig zur Trajektorienbestimmung eine Karte des Objektraums gebildet, weshalb es auch als SLAM (Simultaneous Localization and Mapping) bekannt geworden ist (Handbuch der Geodäsie: [Simultaneous Localization and Mapping](#)). Streng genommen ist SLAM ein absolutes Verfahren, da es innerhalb der simultan gebauten „übergeordneten“ Karte eine absolute Trajektorie liefert, allerdings in einem lokalen Koordinatensystem. Für den Übergang in das erdfeste System sind dann weitere Informationen notwendig, wie z. B. Passpunkte oder GNSS-Beobachtungen. Da sich SLAM aus einer Erweiterung von relativen Verfahren ohne zusätzliche Sensorik ergibt, ist es hier im Abschnitt der relativen Verfahren erwähnt.

## 2.3 Absolute Messverfahren

### 2.3.1 GNSS

#### Positionsbestimmung

GNSS-Empfänger (Global Navigation Satellite System, z. B. GPS) sind die in Mobile-Mapping-Systemen am häufigsten eingesetzten absoluten Sensoren zur Bestimmung der Position des bewegten Objektes. Dabei werden meist differentielle Auswerteverfahren auf Basis von Trägerphasenbeobachtungen eingesetzt, da hier unter Idealbedingungen Positionsgenauigkeiten im Zentimeterbereich und Datenraten bis zu 20 Hz oder sogar mehr möglich sind. Für Details zur Funktionsweise von GNSS und zu den Prinzipien unterschiedlicher Auswerteverfahren sei auf

entsprechende Literatur (Hofmann-Wellenhof et al. 2008 [20]) verwiesen. Es soll jedoch auf zwei Aspekte eingegangen werden, die bei der Verwendung von GNSS auf bewegten Systemen eine Rolle spielen. Beide ergeben sich aus der Tatsache, dass bei bewegten Systemen, insbesondere bei bodengebundenen, die GNSS-Bedingungen eben nicht immer ideal sind und sich zudem ständig ändern.

Zum einen führen Gebäude, Brücken und Vegetation häufig zu Abrissen einzelner oder aller Satellitensignale, nach denen die Mehrdeutigkeiten in den Trägerphasenbeobachtungen neu aufgelöst werden müssen. Diese Mehrdeutigkeiten sind die größte Herausforderung bei der zentimetergenauen GNSS Auswertung. Sie aufzulösen ist im Wesentlichen ein Suchproblem, welches im statischen Fall über eine ausreichend lange Beobachtungsdauer (Sekunden bis Minuten) gelöst wird. Bei bewegten Systemen hat man diese Zeit üblicherweise nicht, da währenddessen ja keine oder nur eine ungenaue Positionsbestimmung möglich ist. Daher werden dazu besondere Filterverfahren unter Einbeziehung zusätzlicher Sensoren wie Inertialsensoren eingesetzt (Abschn. 2.4).

Zum anderen führen Mehrwegeeffekte, bei denen zusätzlich oder alternativ zum direkten Signal vom Satelliten ein an Objekten (Häuser, Boden, Fahrzeuge) reflektiertes indirektes Signal den Empfänger erreicht, zu systematischen Abweichungen in der Positionsbestimmung. Diese Effekte ändern sich mit der Position der Satelliten, weshalb im statischen Fall das Problem wie oben durch eine ausreichend lange Beobachtungsdauer (Stunden) umgangen werden kann. Bei bewegten Systemen ist das nicht möglich, weil sich die Effekte auch mit der Bewegung des Empfängers ändern.

### **Orientierungsbestimmung**

Wenn man zwei GNSS-Antennen auf der Plattform befestigt, spannen diese eine kurze lokale Basislinie auf. Die Auswertung dieser Basislinie liefert einen absoluten Vektor im erdfesten Koordinatensystem und damit zwei absolute Orientierungswinkel der Plattform. Mit drei Antennen lässt sich so die vollständige Orientierung bestimmen. Auf Schiffen und Flugzeugen werden diese auch als GNSS-Kompass bezeichnete Systeme häufig eingesetzt. Besondere Herausforderungen ergeben sich allerdings beim Einsatz von günstigen Empfängern auf Plattformen mit Platz- und Gewichtsbeschränkungen. Hier werden ebenfalls Kombinationen mit anderen Sensoren eingesetzt [21], um Signalunterbrechungen zu überbrücken und Mehrdeutigkeiten schnell zu lösen.

### **2.3.2 Neigungssensorik und Kompass**

Durch den Erdschwerevektor und den Erdmagnetfeldvektor sind (dort wo die Vektoren nicht parallel oder antiparallel sind) zwei Achsen des Navigationskoordinatensystems („North“ und „Up“) eindeutig bestimmt. Durch die Beobachtung dieser beiden Vektoren im Plattformkoordinatensystem lässt sich also prinzipiell die Orientierung  $C_b^n$  der Plattform (Rotation ins Navigationssystem) berechnen. In der Praxis gibt es allerdings bei der Beobachtung beider Vektoren Schwierigkeiten, die im Folgenden kurz erläutert werden.

## **Erdschwere**

Wie schon in Abschn. 2.2.1 gezeigt, kann mit Beschleunigungssensoren der Vektor der Erdschwere gemessen werden, der allerdings im Falle einer bewegten Plattform von einer translatorischen bewegungsinduzierten Beschleunigung überlagert wird.<sup>5</sup> Es gibt zwei Möglichkeiten, damit umzugehen. In einem Fall wird die translatorische Beschleunigung mit anderen Sensoren (z. B. GNSS) beobachtet und man kann die Erdschweremessung so korrigieren. Das geschieht z. B. bei GNSS/IMU basierten Systemen, in denen durch die Fusion der unterschiedlichen Sensoren die Schwerebeschleunigung und die translatorische Beschleunigung getrennt werden können (Abschn. 2.4). Im anderen Fall, wenn man keine unabhängige Information über die translatorische Beschleunigung hat, kann diese unter der Annahme, dass sie immer nur kurzzeitig auftritt und sich im langfristigen Mittel zu Null addiert, mit Hilfe eines Tiefpassfilters unterdrückt werden. Das ist die üblicherweise in Neigungssensoren eingesetzte Methode, die jedoch gleichzeitig dazu führt, dass die Dynamik der Neigungsmessung so stark eingeschränkt wird, dass sie eigentlich nur für statische Anwendungen verwendet werden kann.

## **Erdmagnetfeld**

Der Magnetfeldsensor misst den lokalen Vektor des Erdmagnetfeldes. Projiziert auf die Ebene senkrecht zur Gravitation zeigt dieser in die y-Richtung („North“) des Navigationskoordinatensystems. Leider wird das Erdmagnetfeld durch in der Nähe des Sensors befindliche ferromagnetische Materialien überlagert oder gestört. Diese Störungen lassen sich, wenn sie von Materialien kommen, die sich innerhalb des Plattformsystems nicht bewegen, teilweise mit aufwändigen Verfahren [22] kompensieren. Störungen durch Materialien in der Umgebung (z. B. durch Gebäude oder Fahrzeuge) können aber immer noch zu Problemen führen. Die Größe der Abweichung hängt von dem Abstand und der Menge des störenden Materials ab und ist nicht oder nur schwer kalkulierbar. So zeigt z. B. die magnetfeldbasierte Bestimmung der Nordrichtung innerhalb eines Gebäudes schon durch die verbauten Materialien einige Grad Abweichung. Diese kann aber beispielsweise in der Nähe eines Fahrstuhls leicht auf bis zu 45° oder mehr anwachsen.

## **Erdrotation**

Der Vollständigkeit halber sei an dieser Stelle noch erwähnt, dass die Beobachtung des Erdrotationsvektors durch Drehratensensoren bei bekannter Position im erdfesten System ebenfalls die Bestimmung der Nord-Richtung ermöglicht [13]. Die Präzision der Drehratensensoren muss dazu allerdings höher als die Rotationsrate der Erde sein, was im Falle von MEMS-basierten Sensoren nicht gegeben ist. Weiterhin ist dieses Verfahren nur im statischen Fall möglich, weshalb es für mobile Multisensorsysteme lediglich zur Initialisierung eingesetzt werden kann.

---

<sup>5</sup> Realistische Beschleunigungs- und Abbremsvorgänge eines Fahrzeuges im Bereich von -3g bis 3g führen beispielsweise zu Abweichungen bis zu 15°, wenn die translatorische Komponente ignoriert wird.



### 2.3.3 Bündelausgleichung und SLAM

Bei der Bündelausgleichung werden in einem prinzipiell beliebig großen Satz von sich überlappenden Fotos die Kamerapositionen und -orientierungen aller Bilder sowie die Koordinaten von in den Bildern abgebildeten und wiedergefundenen Objektpunkten in einem gemeinsamen, zunächst lokalen Koordinatensystem bestimmt [1]. Das Verfahren der Bündelausgleichung kann somit als eine Art „absoluter Sensor“ für ein bewegtes Kamerasystem gesehen werden. Wie schon in Abschn. 2.2.5 erwähnt, lässt sich dieses lokale Koordinatensystem dann durch die Verwendung von Passpunkten in ein Zielkoordinatensystem überführen. Ein Nachteil der Bündelausgleichung ist, dass die daraus berechnete Trajektorie durch den erheblichen Rechenaufwand erst nach einer nachträglichen Auswertung zur Verfügung steht (einige Stunden Rechenzeit, anhängig vom der Leistungsfähigkeit des Computers, der Anzahl der Bilder und der gewünschten Auflösung).

Die Bündelausgleichung ist eng verwandt mit dem vollständigen SLAM-Problem, bei dem die gesamte Trajektorie und die Karte, also die Positionen aller Objektpunkte, in einem globalen Ausgleich geschätzt werden, was auch nur dann möglich ist, wenn zu Beginn der Berechnung bereits alle Beobachtungen vorliegen. Wie in Abschn. 2.2.5 bereits beschrieben, gibt es aber auch Verfahren, bei denen man ausgehend von der Idee des Scan-Matching oder der Visuellen Odometrie die aktuelle Position und Orientierung schätzt und dabei ständig neue Objektpunkte hinzunimmt bzw. die Position der alten verbessert (Online-SLAM). Bei der inkrementellen bzw. gleitenden Bündelausgleichung [23] wird zusätzlich zu regelmäßigen Zeitpunkten das letzte Trajektorienstück mit einer Bündelausgleichung neu geschätzt, um so die Genauigkeit der Objektpunkte und der aktuellen Positions- und Orientierungsschätzung zu verbessern. Die Bündelausgleichung wird somit echtzeitfähig.

### 2.3.4 Map-Matching

Ganz allgemein bezeichnet Map-Matching das Einpassen von Beobachtungen in eine bekannte Karte. Entspricht z. B. die bekannte Karte der Beobachtung des Laserscanners in einer Epoche und wird der Scan der nächsten Epoche in diese Karte durch Scan-Matching (z. B. mittels ICP) eingepasst, so ist das eine Art von Map-Matching. Gleiches gilt bei SLAM Verfahren durch das Einpassen von Beobachtungen in die globale Karte. Map-Matching ist auch auf Basis der Trajektorie möglich, wenn eine Karte mit den möglichen Trajektorien (z. B. eine Straßenkarte) existiert. Diese Methode wurde schon in den 80er-Jahren in Fahrzeugnavigationssystemen zur Ergänzung der damals künstlich verschlechterten GPS-Beobachtungen eingesetzt. Dabei werden aus Sensordaten Koordinaten-, Winkel- oder Krümmungsprofile der Trajektorie berechnet und diese mittels Kreuzkorrelation mit den aus einer Straßenkarte extrahierten Profilen verglichen [24]. Dadurch kann die wahrscheinlichste aktuelle Position innerhalb der Karte ermittelt werden.

Im weitesten Sinne sind alle Verfahren zur absoluten Trajektorienbestimmung Map-Matching Verfahren: Durch die Beobachtung von Objekten, deren Positionen in einem bestimmten Koordinatensystem bekannt sind („Map“), versucht man die eigene Position (und Orientierung) in das Koordinatensystem der Objekte

einzupassen („Matching“). Bei der klassischen geodätischen Punktbestimmung sind diese Objekte vermarktete Punkte bekannter Koordinaten, die z. B. mit Hilfe von Einmessungsskizzen gefunden werden können und dann durch Anmessung über Strecken und Richtungen zur eigenen Positionsbestimmung verwendet werden. Ein anderes Beispiel ist eine GNSS- Auswertung. Die Satelliten bilden die Punkte sich in diesem Fall ändernder aber bekannter Koordinaten; die Schätzung der eigenen Position im GNSS-Koordinatensystem wird so optimiert, dass die Beobachtungen (z. B. Pseudostrecken) bestmöglich zur aktuellen „Karte“ der Satelliten passen. Während in den hier genannten Beispielen die Kartenelemente punktförmig sind („Landmarken“), können diese bei der Verwendung flächenhafter Messverfahren (Handbuch der Geodäsie: [Flächenhafte Abtastung mit Laserscanning: Messtechnik, flächenhafte Modellierungen und aktuelle Entwicklungen im Bereich des terrestrischen Laserscannings](#)) auch aus Oberflächen bestehen.

## 2.4 Filterung und Sensorfusion

Würden wir die Position und Orientierung eines statischen Objektes möglichst genau und zuverlässig bestimmen wollen, würden wir eine Vielzahl verschiedener unabhängiger Messungen mehrfach durchführen und so eine hohe Überbestimmung erreichen. Im Falle der eben beschriebenen absoluten Verfahren und im Falle eines sich bewegenden Objektes ist diese Überbestimmung nicht ohne weiteres erreichbar. So würden zum Beispiel die drei Freiheitsgrade der Position in einer einzelnen Epoche nur durch die Messungen des GNSS-Empfängers beobachtet werden können. Unter Umständen sind diese, abgesehen von zufälligen Beobachtungsabweichungen, zusätzlich noch durch systematische Abweichungen oder grobe Fehler überlagert.<sup>6</sup> Es gibt drei Möglichkeiten mit dieser fehlenden Redundanz umzugehen:

- Die Einbeziehung von Modellwissen über das System. Sich bewegende Plattformen können aufgrund ihrer Massenträgheit nicht beliebig schnelle Positions- und Orientierungsänderungen vornehmen. Es lässt sich also für die Trajektorie in einem bestimmten Zeitabschnitt eine Glattheitsannahme treffen. Allgemeiner formuliert bedeutet das: Wenn wir wissen, welchen Zustand (inklusive der Unsicherheit darüber) ein System zum letzten Zeitpunkt hatte, und wir eine Ahnung davon haben, was seitdem passiert sein könnte (z. B. über ein Systemmodell oder relative Messverfahren), so können wir diese Informationen als Vorbedingung in die Schätzung des aktuellen Zustandes einfließen lassen und so eine verbesserte Genauigkeit und Zuverlässigkeit erreichen.
- Einbindung zusätzlicher Sensoren. Die Fusion möglichst vieler verschiedener Messverfahren, ob relativ oder absolut, direkt oder indirekt, in die Schätzung unter statistisch korrekter Berücksichtigung der individuellen Unsicherheiten dieser Verfahren erhöht ebenfalls die Genauigkeit und Zuverlässigkeit.

---

<sup>6</sup> Letztere treten zum Beispiel bei GNSS-Beobachtungen auf, wenn lediglich das indirekte, an einem Objekt reflektierte Satellitensignal die Antenne erreicht.

- Einbindung von Modellwissen über die Umgebung. Einige der indirekten Verfahren benötigen Informationen über die Umgebung, z. B. in Form einer Karte. Diese kann, wie in Fall von SLAM, während des Schätzvorgangs erzeugt werden, oder wie im Fall von Passpunkten vorher bekannt sein. Das Modellwissen kann im Falle indirekter Verfahren die Anzahl unabhängiger Messungen erhöhen oder diese erst ermöglichen. Gleichzeitig kann es als die Bewegung einschränkende Nebenbedingung in die Trajektorien-schätzung eingehen und diese so verbessern.

Rekursive Bayes-Schätzverfahren, z. B. in Form von Kalman-Filtern oder dessen Varianten, bieten das methodische Gerüst, um alle drei genannten Möglichkeiten gleichzeitig umzusetzen. Im Folgenden wird zunächst das Kalman-Filter, welches das bekannteste dieser Verfahren darstellt, kurz erläutert. Dann wird anhand von Beispielen dargestellt, wie sich Modellwissen über das System und Informationen weiterer Sensoren in das Kalman-Filter einbinden lassen. Eine verallgemeinerte Darstellung der rekursiven Bayes-Schätzung führt schließlich zum Partikel-Filter und zur Erzeugung und Einbindung von Modellwissen über die Umgebung (z. B. SLAM).

### 2.4.1 Das Kalman-Filter

Beim diskreten Kalman-Filter wird davon ausgegangen, dass sich der zu schätzende Zustand  $\mathbf{x}_k$  eines Systems zu einem Zeitpunkt  $t_k$  (also in diesem Fall z. B. die Position und Orientierung der Plattform) durch einen linearen Zusammenhang aus dem vorherigen Zustand  $\mathbf{x}_{k-1}$ , eventuell bekannten Einflussgrößen („Stellgrößen“)  $\mathbf{u}_k$  (mit Kovarianz  $\Sigma_{uu}$ ) und einem normalverteilten stochastischen Anteil („Störgröße“)  $\mathbf{w}_k \sim N(0, \Sigma_{ww})$  ergibt:

$$\mathbf{x}_k = \mathbf{T}\mathbf{x}_{k-1} + \mathbf{B}\mathbf{u}_k + \mathbf{C}\mathbf{w}_k. \tag{4}$$

Weiterhin wird davon ausgegangen, dass der Zustand  $\mathbf{x}_k$  durch eine linear mit ihm zusammenhängende Beobachtung  $\mathbf{l}_k$  (also z. B. dem Ergebnis einer GPS Auswertung) und eine ebenfalls normalverteilten Beobachtungsabweichung  $\epsilon_k = N(0, \Sigma_{ll})$  ermittelt wird:

$$\mathbf{l}_k = \mathbf{A}\mathbf{x}_k + \epsilon_k. \tag{5}$$

Die bekannten Kalman-Filter Gleichungen ergeben sich dann zu

#### Vorhersageschritt

$$\begin{aligned} \bar{\mathbf{x}}_k &= \mathbf{T}\mathbf{x}_{k-1} + \mathbf{B}\mathbf{u}_k \\ \Sigma_{\bar{\mathbf{x}},k} &= \mathbf{T}\Sigma_{\mathbf{x},k-1}\mathbf{T}^T + \mathbf{B}\Sigma_{uu}\mathbf{B}^T + \mathbf{C}\Sigma_{ww}\mathbf{C}^T \end{aligned} \tag{6}$$

## Korrekturschritt

$$\begin{aligned}
 \mathbf{d}_k &= \mathbf{l}_k - \mathbf{A} \bar{\mathbf{x}}_k \\
 \boldsymbol{\Sigma}_{dd,k} &= \mathbf{A} \boldsymbol{\Sigma}_{\bar{\mathbf{x}},k} \mathbf{A}^T + \boldsymbol{\Sigma}_{ll} \\
 \mathbf{K}_k &= \boldsymbol{\Sigma}_{\bar{\mathbf{x}},k} \mathbf{A}^T \boldsymbol{\Sigma}_{dd,k}^{-1} \\
 \mathbf{x}_k &= \bar{\mathbf{x}}_k + \mathbf{K}_k \mathbf{d}_k \\
 \boldsymbol{\Sigma}_{xx,k} &= \boldsymbol{\Sigma}_{\bar{\mathbf{x}},k} \mathbf{T}^T - \mathbf{K}_k \boldsymbol{\Sigma}_{dd,k} \mathbf{K}_k^T
 \end{aligned} \tag{7}$$

Diesen sich immer wiederholenden Vorgang bestehend aus Vorhersage und Korrektur haben alle rekursiven Bayes-Schätzverfahren gemeinsam. Im Vorhersageschritt wird die zum letzten Zeitpunkt beste Schätzung  $\mathbf{x}_{k-1}$  inklusive ihrer Unsicherheit  $\boldsymbol{\Sigma}_{xx,k-1}$  mit Hilfe eines Systemmodells  $\mathbf{T}$  und dessen Unsicherheit  $\mathbf{C} \boldsymbol{\Sigma}_{ww} \mathbf{C}^T$  sowie einer bekannten Einflussgröße  $\mathbf{u}_k$  und dessen Unsicherheit  $\boldsymbol{\Sigma}_{uu}$  zu einer Vorhersage  $\bar{\mathbf{x}}_k$  zum aktuellen Zeitpunkt fortgeschrieben. Im Korrekturschritt wird dann auf Basis dieser Vorhersage eine Messung  $\mathbf{A} \bar{\mathbf{x}}_k$  prädiziert, deren Unterschied  $\mathbf{d}_k$  (Innovation) zur tatsächlich beobachteten Messung  $\mathbf{l}_k$  zur Korrektur des vorhergesagten Zustandes verwendet wird. Wie viel Einfluss die Innovation auf die Korrektur hat, wird dabei durch die Unsicherheit der Vorhersage  $\boldsymbol{\Sigma}_{\bar{\mathbf{x}},k}$  und die Unsicherheit der Messung  $\boldsymbol{\Sigma}_{ll}$  bestimmt.

Das Kalman-Filter ist unter der Annahme, dass die Modelle linear und die Abweichungen normalverteilt sind, ein optimaler Schätzer im Sinne der kleinsten Quadrate. In den meisten Fällen sind diese Annahmen jedoch nicht gegeben. So sind die Modelle im Allgemeinen nicht linear:

$$\begin{aligned}
 \mathbf{x}_k &= f(\mathbf{x}_{k-1}, \mathbf{u}_k, \mathbf{w}_k) \\
 \mathbf{l}_k &= h(\mathbf{x}_k, \boldsymbol{\epsilon}_k)
 \end{aligned} \tag{8}$$

Da Normalverteilungen unter nicht linearen Transformationen nicht mehr normal verteilt sind, gibt es zwei Strategien, die Kalman-Filter-Gleichungen, wie sie oben dargestellt wurden immer noch anwendbar zu machen. Eine Möglichkeit ist es, die Modelle zu linearisieren, was zum sog. Erweiterten (engl. Extended) Kalman-Filter (EKF) führt. Für die Aufstellung der System- und Beobachtungsgleichungen, insbesondere zur Transformation der Kovarianzen, werden die Gleichung  $f$  und  $h$  nach Taylor bis zu Termen erster Ordnung entwickelt:

$$\mathbf{T}_k = \left. \frac{\partial f}{\partial \mathbf{x}_k} \right|_{\mathbf{x}_{k-1}}, \mathbf{B}_k = \left. \frac{\partial f}{\partial \mathbf{u}_k} \right|_{\mathbf{u}_k}, \mathbf{C}_k = \left. \frac{\partial f}{\partial \mathbf{w}_k} \right|_{\mathbf{w}_k}, \mathbf{A}_k = \left. \frac{\partial h}{\partial \mathbf{x}_k} \right|_{\mathbf{x}_k} \tag{9}$$

Während die Prädiktion des Zustandes und der Messung direkt mit den nicht linearen Funktionen erfolgen kann, werden die restlichen Gleichungen mit Hilfe der Jacobi-Matrizen transformiert.

Diese Variante ist durch die Linearisierung nur noch eine Approximation und daher keine optimale Lösung mehr. Sie ist die am häufigsten eingesetzte nicht-lineare Kalman-Filter-Variante. Jedoch kann es bei hohen Nichtlinearitäten der

Modelle und bei großen Unsicherheiten der Zustände und Beobachtungen aufgrund der Linearisierung zu Ungenauigkeiten kommen.

In diesen Fällen kann ein Unscented Kalman-Filter (UKF) bessere Ergebnisse liefern. Dabei wird die aktuelle Zustandsschätzung inklusive ihrer Kovarianz durch eine Menge von  $2n + 1$  sog. Sigma-Punkten  $X_i$  repräsentiert:

$$\mathbf{x}_k, \Sigma_{xx,k} \Rightarrow \{X_i\}, i = 1 \dots 2n, \quad (10)$$

wobei  $n$  die Dimension des Zustandsvektors ist. Diese Sigma-Punkte werden nach einer bestimmten Vorschrift so aus dem Mittelwert und der Kovarianz des Zustandsvektors berechnet, dass die ersten Momente ihrer statistischen Verteilung unter nicht-linearen Transformationen möglichst erhalten bleiben. Nach der Transformation der Punkte durch die im Allgemeinen nicht linearen Funktionen  $f$  und  $h$  an den entsprechenden Stellen der rekursiven Schätzung werden aus deren Verteilung wieder Mittelwert und die Kovarianz zurückgerechnet. Die Gleichungen für Vorhersage und Korrektur sind dann sehr ähnlich zu den bereits gezeigten Gleichungen für das lineare Kalman-Filter. Auf eine detaillierte Beschreibung des Algorithmus sowie des Verfahrens zur Berechnung der Sigmapunkte und der Rekonstruktion von Mittelwert und Kovarianz wird an dieser Stelle verzichtet. Dazu sei z. B. auf Julier et al. [25] verwiesen.

### 2.4.2 Modellierung des Systemverhaltens

Die Modellierung des zeitlichen Verhaltens des Systems spielt eine zentrale Rolle bei der Kalman-Filterung. Je besser sie ist, desto besser erfüllt das Filter seinen Zweck, den geschätzten Zustand trotz mangelnder Redundanz durch die Beobachtung möglichst genau und zuverlässig zu schätzen. Wie das Systemverhalten modelliert wird, hängt von dem Modellwissen über das System und eventuellen bekannten oder unbekanntem Einflussgrößen auf den Systemzustand ab. Dies soll am Beispiel der Bewegung einer Plattform in zwei Dimensionen diskutiert werden. Die Aufgabe der Trajektorienschätzung besteht also in der Bestimmung einer Koordinate  $[p_x, p_y]_k$  und eines Orientierungswinkels  $\varphi_k$  für alle Zeitpunkte  $t_k$ . Wir beginnen damit, dass wir nur wenig über die Plattform wissen. Wir zeigen beispielhaft, welche Möglichkeiten zur Modellierung des Systems bestehen. Sukzessive werden dann weiteres Modellwissen sowie Beobachtungen zusätzlicher Sensoren in die Vorhersage des Systemverhaltens eingebunden.

#### Glattheitsannahme durch Plattformträgheit

Nehmen wir zunächst an, es stände ein Sensor für die Position und einer für die Orientierung zur Verfügung, was zu einem sehr einfachen Messmodell führt. Nehmen wir weiter an, wir hätten keine Informationen über die Art der Plattform, womit in diesem Fall die physikalische Kopplung zwischen Position und Orientierung gemeint ist. Wir hätten also keine andere Wahl, als Position und Orientierung getrennt voneinander zu modellieren.<sup>7</sup> Abhängig von der zu erwartenden Trägheit des Sys-

<sup>7</sup> In diesem Fall könnte man sie auch getrennt voneinander in zwei unabhängigen Filtern schätzen.

tems müssen wir uns jetzt entscheiden, ob wir im Modell eine konstante Position, eine konstante Geschwindigkeit oder eine konstante Beschleunigung der Plattform annehmen. Gleiches gilt für die Dynamik des Winkels. Die Unsicherheit des Modells wird durch die Störgröße modelliert. Entscheiden wir uns für eine konstante erste Ableitung sowohl in der Position als auch in der Rotation (so würde man vielleicht den Flug einer Frisbee-Scheibe modellieren), so setzt sich der Zustandsvektor  $\mathbf{x}_k = [p_x, p_y, v_x, v_y, \varphi, \omega]_k^T$  aus der Position, der Geschwindigkeit, dem Winkel und der Winkelgeschwindigkeit zusammen und das Modell sieht wie folgt aus:

$$\begin{aligned} \mathbf{p}_k &= \mathbf{p}_{k-1} + \mathbf{v}_{k-1} \Delta t \\ \mathbf{v}_k &= \mathbf{v}_{k-1} + \mathbf{w}_{v,k} \Delta t^2 \\ \boldsymbol{\varphi}_k &= \boldsymbol{\varphi}_{k-1} + \boldsymbol{\omega}_{k-1} \Delta t \\ \boldsymbol{\omega}_k &= \boldsymbol{\omega}_{k-1} + \mathbf{w}'_{\cdot,k} \Delta t^2 \end{aligned} \quad (11)$$

Die Störgrößen  $[\mathbf{w}_v, \mathbf{w}_\varphi]_k^T \sim N(0, \boldsymbol{\Sigma}_{wv})$  repräsentieren hier die Unsicherheit des Modells, also dessen Abweichung von der Realität durch ein normalverteiltes Beschleunigungsrauschen in Position und Winkel. Man kann auch sagen, die Geschwindigkeiten (translatorisch und rotatorisch) werden als Random-Walk-Prozesse modelliert. Da dieses sehr einfache Modell üblicherweise nicht der realen Bewegung entspricht, kann es passieren, dass abhängig von den Werten des Störgrößenrauschens und des Messrauschens echte Bewegungen vom Filter als Messabweichung interpretiert und weggefiltert werden oder Messabweichung als echte Bewegung in die Schätzung eingehen. Eine bessere Modellierung der Bewegung oder weitere Sensoren sind hier also erstrebenswert.

### Modellierung einer spurgeführten Plattform

Nehmen wir jetzt an, wir hätten mehr Informationen über die Kinematik der Plattform. Sie bewegt sich immer in Richtung ihrer Ausrichtung, wie das in etwa bei einem spurgeführten Fahrzeug gegeben ist. Nimmt man wieder eine konstante Geschwindigkeit sowie eine konstante Winkelgeschwindigkeit an, so kann man den Zustandsvektor  $\mathbf{x}_k = [p_x, p_y, v, \varphi, \omega]$  im Gegensatz zum Beispiel vorher um eine Dimension reduzieren und das Modell sieht wie folgt aus:

$$\begin{aligned} p_{x,k} &= p_{x,k-1} + \sin(\varphi_{k-1}) v_{k-1} \Delta t \\ p_{y,k} &= p_{y,k-1} + \cos(\varphi_{k-1}) v_{k-1} \Delta t \\ v_k &= v_{k-1} + w_{v,k} \Delta t^2 \\ \varphi_k &= \varphi_{k-1} + \omega_{k-1} \Delta t \\ \omega_k &= \omega_{k-1} + w_{\varphi,k} \Delta t^2 \end{aligned} \quad (12)$$

Die Störgröße ist jetzt nur noch zweidimensional. In diesem Beispiel könnte man sogar ohne die direkte Beobachtung der Orientierung auskommen. Durch die Kopplung von Position und Orientierung wird diese indirekt geschätzt. Dennoch werden in der Modellierung der Drehrate und der Länge des Geschwindigkeitsvektors Annahmen gemacht, die für die wenigsten Plattformen immer gültig sind. Auch hier ist eine Unterscheidung zwischen Modellfehlern und Messabweichungen nicht immer möglich, insbesondere wenn diese im gleichen Frequenzbereich liegen.

Die Möglichkeit durch Verbesserung der Vorhersage auf Basis von Stellgrößen oder relativen Messgrößen kann hier helfen.

### Einbindung von Stellgrößen und relativen Beobachtungen

Nehmen wir jetzt an, wir hätten eine Plattform wie im Beispiel vorher, also mit einer Kopplung zwischen Position und Orientierung. Zusätzlich haben wir jedoch jetzt den Lenkradwinkel und die Stellung des Gaspedals zur Verfügung. Diese könnten als bekannte Einflussgrößen (Stellgrößen) in die Modellierung eingebunden werden. Modellannahmen, wie z. B. die einer konstanten Geschwindigkeit, wären nun nicht mehr nötig. Allerdings würde das Modell nun wesentlich komplexer. Um den Einfluss dieser Stellgrößen auf die interessanten Größen, wie Geschwindigkeit und Winkeländerung des Fahrzeugs bestimmen zu können, müssten eine Reihe anderer Größen wie die Lenkübersetzung, das Beschleunigungsverhalten des Fahrzeugs usw. bekannt sein. In diesem Fall gibt es dann eine Vielzahl anderer Modellunsicherheiten, die modelliert werden müssen.

Es existieren jedoch Sensoren, wie z. B. das Odometer und der Drehratensensor, die uns direkt die Auswirkung einer (unbekannten) Stellgröße als Beobachtung liefern (z. B. die Geschwindigkeit in Fahrtrichtung durch Betätigung des Gaspedals oder eine Winkeländerung um die Hochachse durch Drehung des Lenkrads). Diese lassen sich dann trotzdem als Stellgrößen in ein Kalman-Filter einbinden. Das Beispiel von eben würde dann wie folgt aussehen:

$$\begin{aligned} p_{x,k} &= p_{x,k-1} + \sin(\varphi_{k-1}) v_{odo,k} \Delta t \\ p_{y,k} &= p_{y,k-1} + \cos(\varphi_{k-1}) v_{odo,k} \Delta t \\ \varphi_k &= \varphi_{k-1} + \omega_{gyro,k} \Delta t \end{aligned} \quad (13)$$

Dabei sind  $v_{odo}$  und  $\omega_{odo}$  die eben genannten relativen Messungen über die Bewegung; die Beobachtungsabweichungen dieser relativen Messungen gehen als Störgrößenrauschen  $\Sigma_{uu}$  in die Vorhersage mit ein.

An dieser Stelle ist zu bemerken, dass das hier beschriebene Modell genau dem Prinzip der relativen Positionsbestimmung durch Koppelortung (Abschn. 2.2.2) entspricht. Übertragen auf drei Dimensionen und mit einem Beschleunigungs- statt einem Geschwindigkeitssensor entspricht es der Inertialnavigation aus Abschn. 2.2.1. Damit haben wir ein sehr weit verbreitetes Konzept zur Trajektorien-schätzung beschrieben, welches zum Beispiel als „GPS/IMU-Integration“ bekannt ist (siehe zum Beispiel [13] oder [14]). Dabei wird die zeitliche Entwicklung des Objektes nicht modelliert, sondern durch die Inertialsensoren beobachtet. Der absolute Bezug und die Eliminierung der durch die Integration entstehenden Drift geschehen durch die absoluten Beobachtungen eines GPS Empfängers. Ein Beispiel für ein darauf basierendes Filter folgt in Abschn. 4.

### Modellparameter, Formfilter und adaptive Filterung

Am Beispiel der GPS gestützten Koppelortung lassen sich noch einige weitere Konzepte erläutern, die beim Einsatz von Kalman-Filtern zur Trajektorienbestimmung häufig eine Rolle spielen. So kann es zum Beispiel vorkommen, dass einzelne Parameter des Bewegungsmodells oder der Beobachtungsgleichung während der

Filterung mit geschätzt werden müssen. Ein Odometer wie im Beispiel oben liefert somit eigentlich nicht die Geschwindigkeit in Fahrtrichtung, sondern meistens die Anzahl  $N_{odo}$  der Radumdrehungen seit dem letzten Zeitschritt. Diese muss dann noch mit Kenntnis des Raddurchmessers  $D$  in ein Wegstück  $s = \pi D N_{odo}$  umgerechnet werden. Der Raddurchmesser ist jedoch im Allgemeinen nur ungefähr bekannt, bzw. ändert sich durch Abrieb oder Luftdruckänderungen sogar langsam mit der Zeit. Eine Möglichkeit, dieses Problem zu lösen ist es, den Raddurchmesser als Teil des Zustandsvektors mit zu schätzen. Man würde ihn z. B. als konstant modellieren. Ähnlich kann mit dem Bias des Drehratensensors umgegangen werden. Wie in Abschn. 2.2.1 beschrieben, ändert sich das Bias abhängig von der Zeit und der Temperatur, weshalb man es üblicherweise als Random-Walk-Prozess modelliert und ebenfalls mit schätzt.

Mathematisch äquivalent, aber etwas anders motiviert ist die Verwendung des sog. Formfilters (siehe z. B. Li & Kuhlmann [26]). Das Formfilter ermöglicht den Umgang mit nicht weißem, also zeitlich korreliertem Beobachtungsrauschen, wie es z. B. durch Mehrwegeeffekte bei GPS-Beobachtungen auftritt. Dabei wird das Beobachtungsrauschen in zwei Anteile unterteilt, nämlich einen nicht weißen informativen Anteil  $E$  und einen weißen Anteil. Der informative Anteil wird dann als zusätzlicher Parameter mit einem den stochastischen Eigenschaften entsprechenden Modell im Zustandsvektor geschätzt. Mit dem Offset der Drehratensensoren und dem Raddurchmesser als unbekanntem Modellparameter und dem nicht weißen GPS-Rauschen sieht das Systemmodell aus unserem Beispiel dann wie folgt aus:

$$\begin{aligned}
 p_{x,k} &= p_{x,k-1} + \sin(\varphi_{k-1}) \pi D_{k-1} N_{odo,k} \\
 p_{y,k} &= p_{y,k-1} + \cos(\varphi_{k-1}) \pi D_{k-1} N_{odo,k} \\
 \varphi_k &= \varphi_{k-1} + (\omega_{gyro,k} - b_{gyro,k-1}) \Delta t \\
 D_k &= D_{k-1} && \text{(konstanter Raddurchmesser)} \\
 b_{gyro,k} &= b_{gyro,k-1} + w_{gyro,k-1} && \text{(Gyroskop-Bias, Random-Walk-Prozess)} \\
 E_k &= e^{\left(-\frac{\Delta t}{T_{korr}}\right)} E_{k-1} + w_{E,k-1} \\
 &&& \text{(farbiges GPS-Rauschen, Gauss-Markov-Prozess)} \quad (14)
 \end{aligned}$$

Der zeitlich korrelierte Anteil des GPS-Rauschens wird hier als Gauss-Markov-Prozess modelliert,  $T_{korr}$  ist dabei die Korrelationslänge der Autokorrelationsfunktion, die z. B. empirisch bestimmt werden kann. In der Beobachtungsgleichung muss der Anteil  $E_k$  noch von der GPS Beobachtung abgezogen werden.

Es sei an dieser Stelle noch erwähnt, dass dieses Beispiel einen eher demonstrativen als praktischen Charakter hat. Es soll beispielhaft gezeigt werden, auf welche Weise systematische oder stochastische nicht normal-verteilte Messwertabweichungen modelliert werden können und wie Modellparameter ein Teil des zu schätzenden Zustandes werden können. Insbesondere die im statischen Fall erfolgreich eingesetzte Methode des Formfilters zur Berücksichtigung der Mehrwegeeffekte muss bei



sich bewegenden Plattformen nicht notwendigerweise funktionieren. Das zeitliche Verhalten des informativen Anteils  $E$  der GPS-Beobachtung ist vermutlich sehr ähnlich zu dem zeitlichen Verhalten der Bewegung selbst. Das Filter könnte dann, ähnlich wie im ersten Beispiel, nicht zwischen einer wahren Bewegung und einer Messwertabweichung unterscheiden. Eine intuitive Herangehensweise, die häufig bei der Fehlersuche und der Optimierung solcher Filter hilft, ist die, sich zu fragen, welche Möglichkeiten das Filter hat, um die Innovation, also die Abweichung von Modell und Vorhersage, zu minimieren. Liegt also in diesem Beispiel die beobachtete Position einen halben Meter neben der durch das Modell vorhergesagten, so hat das Filter zwei Möglichkeiten, diese Abweichung zu erklären. Entweder hat sich der informative Anteil  $E$  der Messabweichung verändert oder die Plattform hat sich bewegt. Haben beide Möglichkeiten eine ähnliche Wahrscheinlichkeit, ist also ihr Zeitverhalten ähnlich modelliert, kann das Filter keine gute Schätzung vornehmen. Es gibt auch formelle Methoden, um diese sog. Beobachtbarkeit von Parametern zu bestimmen, auf die jedoch hier nicht weiter eingegangen werden soll. Details dazu finden sich z. B. in Heunecke et al. [27].

Ergänzend sei noch erwähnt, dass die gleichzeitige Schätzung von Modellparametern und Zustandsgrößen in der Literatur auch adaptive Filterung genannt wird (z. B. Heunecke [28]). Gemeint ist dabei allerdings allgemeiner die Verwendung nicht starrer Modelle, die sich auch mit anderen Methoden wie z. B. Interacting Multiple Model Filtern (z. B. Bloom [29]) realisieren lässt.

### 2.4.3 Rekursive Bayes-Schätzung und das Partikel-Filter

Die Trajektorienbestimmung mit Hilfe des oben eingeführten Kalman-Filters und dessen Varianten lässt sich auch mit probabilistischen Methoden formulieren (eine detaillierte mathematische Beschreibung findet sich z. B. in Thrun et al. [30]). Der Zustand eines dynamischen Systems zu einem Zeitpunkt  $t_k$  (also z. B. die Position und Orientierung der Plattform) unter Berücksichtigung aller Beobachtungen  $\mathbf{L}_k = \{\mathbf{l}_0, \dots, \mathbf{l}_k\}$  und Stellgrößen  $\mathbf{U}_k = \{\mathbf{u}_0, \dots, \mathbf{u}_k\}$  bis zu diesem Zeitpunkt wird dabei durch die bedingte Wahrscheinlichkeitsdichtefunktion  $p(\mathbf{x}_k | \mathbf{L}_k, \mathbf{U}_k)$  repräsentiert. („Die Wahrscheinlichkeit von  $\mathbf{x}_k$  bei gegebenen  $\mathbf{L}_k$  und  $\mathbf{U}_k$ “). Diese kann auf Basis des „Bayes Theorems“

$$p(\mathbf{x}_k | \mathbf{L}_k, \mathbf{U}_k) = \frac{p(\mathbf{L}_k, \mathbf{U}_k | \mathbf{x}_k) p(\mathbf{x}_k)}{p(\mathbf{L}_k, \mathbf{U}_k)} \quad (15)$$

und unter den Annahmen, dass die Messungen  $\{\mathbf{l}_0, \dots, \mathbf{l}_k\}$  statistisch unabhängig sind und dass der Zustand des Systems  $\mathbf{x}_k$  nur von seinem unmittelbaren zeitlichen Vorgänger  $\mathbf{x}_{k-1}$  abhängt (Markov-Prozess 1. Ordnung), durch ein rekursives Verfahren berechnet werden:

#### Vorhersageschritt

$$p(\mathbf{x}_k | \mathbf{L}_{k-1}, \mathbf{U}_k) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{u}_k) p(\mathbf{x}_{k-1} | \mathbf{L}_{k-1}, \mathbf{U}_{k-1}) d\mathbf{x}_{k-1} \quad (16)$$

## Korrekturschritt

$$p(\mathbf{x}_k | \mathbf{L}_k, \mathbf{U}_k) = \frac{p(\mathbf{I}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{L}_{k-1}, \mathbf{U}_k)}{p(\mathbf{I}_k | \mathbf{L}_{k-1}, \mathbf{U}_k)} \quad (17)$$

Im Vorhersageschritt wird mit Hilfe des Systemmodells  $p(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{u}_k)$ , also dem Vorwissen über die zeitliche Entwicklung des Systems inklusive der aktuellen Stellgröße, aus der letzten Schätzung  $p(\mathbf{x}_{k-1} | \mathbf{L}_{k-1}, \mathbf{U}_{k-1})$  eine Vorhersage  $p(\mathbf{x}_k | \mathbf{L}_{k-1}, \mathbf{U}_k)$  prädiziert. Danach wird im Korrekturschritt diese Vorhersage mit Hilfe der sog. Likelihood  $p(\mathbf{I}_k | \mathbf{x}_k)$ , also der Wahrscheinlichkeit der Beobachtung bei gegebenem Zustand, berechnet. Der Term  $p(\mathbf{x}_k | \mathbf{L}_{k-1}, \mathbf{U}_k)$  ist ein Normalisierungsfaktor.

Die hier aufgeführten Gleichungen stellen die Grundlagen der rekursiven Bayes-Schätzung dar, die Integrale sind jedoch im Allgemeinen nicht analytisch lösbar. Erst durch die vereinfachenden Annahmen, dass alle Wahrscheinlichkeitsverteilungen normal, also durch Mittelwert und Kovarianz parametrisierbar sind, und dass die zugrunde liegenden System- und Messmodelle linear sind, werden aus den beiden Gl. (16) und Gl. (17) die weiter oben eingeführten Gleichungen des Kalman-Filters. Die Aufhebung der Linearitätsanforderung führt dann zu approximativen Verfahren wie dem Unscented und dem Extended Kalman-Filter.

Eine Möglichkeit, die rekursive Bayes-Schätzung ohne Anforderungen an die Verteilungen und Modelle zu realisieren, ist es, die Wahrscheinlichkeitsdichteverteilungen wie bei der Monte-Carlo-Simulation als stochastisch generierte Menge von Stichproben („Partikel“) zu repräsentieren und diese jede für sich entsprechend den System- und Messmodellen zu prädizieren und zu filtern. Dieses Verfahren führt zum sog. Partikel-Filter. Die Formulierung der System- und der Beobachtungsgleichungen erfolgt dabei äquivalent zu den vorher beschriebenen Verfahren, so dass auch die Überlegungen zur Systemmodellierung (Abschn. 2.4.2) hier genauso gelten. Auf die Implementierung des Partikel-Filters, welcher auch in verschiedenen Varianten existiert, wird jedoch an dieser Stelle nicht weiter eingegangen. Dafür sei z. B. auf Thrun et al. [30]. verwiesen.

Ein wesentlicher Vorteil des Partikel-Filters gegenüber den vorgestellten Kalman-Filter Konzepten ist, dass es damit möglich ist, multimodale Wahrscheinlichkeiten zu modellieren, wohingegen die Kalman-Filter von einer unimodalen Verteilung ausgehen. Auf diese Weise können z. B. mehrere Hypothesen für die Zustände modelliert werden, wenn z. B. die Beobachtungen mehrdeutig sind. Das könnte dann der Fall sein, wenn eine Trajektorieneinpassung über ein Map-Matching-Verfahren eingesetzt wird und zum aktuellen Profil der Trajektorie noch mehrere passende Kandidaten in der Karte gefunden werden. Genauso führt die Beobachtung nicht eindeutig zuordnungsbarer Landmarken, wie Türen oder Fenster, zu Mehrfachhypothesen für die geschätzte Position bzw. Orientierung, die sich jedoch im besten Fall im zeitlichen Verlauf auflösen. Der Preis des Partikel-Filters ist allerdings ein signifikant höherer Rechenaufwand.

Ein bemerkenswerter Unterschied zu den vorher beschriebenen Filtern KF, UKF und EKF ist der, dass der Einfluss der Prozess- und Messunsicherheiten auf die

Schätzung durch das Ziehen neuer Samples aus den entsprechenden Verteilungsfunktionen realisiert wird und nicht durch die deterministische Berechnung der Kovarianzen oder wie im Falle des UKF der Sigmapunkte. Das führt natürlicherweise dazu, dass jeder Durchlauf des Filters bei identischen Anfangsbedingungen, Beobachtungen und Stellgrößen zu unterschiedlichen Ergebnissen führt. Dieser Effekt ist größer, je kleiner die Anzahl der verwendeten Partikel ist.

Ohne auf Details einzugehen, soll hier kurz erwähnt werden, wie sich das schon beschriebene SLAM-Problem als rekursive Bayes-Schätzung formulieren lässt. Da neben der Trajektorie auch die Karte  $\mathbf{m}$ , die die Umgebung repräsentiert, bestimmt werden soll, wird diese in die zu schätzende Wahrscheinlichkeitsdichte aufgenommen, die wie folgt dann faktorisiert

$$p(\mathbf{x}_k, \mathbf{m} | \mathbf{L}_k, \mathbf{U}_k) = p(\mathbf{x}_k | \mathbf{L}_k, \mathbf{U}_k) p(\mathbf{m} | \mathbf{x}_k, \mathbf{L}_k) \quad (18)$$

und z. B. mit Hilfe eines Partikel-Filters bestimmt werden kann. Wie die Repräsentation der Karte  $\mathbf{m}$  aussieht, hängt von der Anwendung ab. Bei bildbasierten Verfahren könnte  $\mathbf{m}$  z. B. eine Liste aller bisher beobachteten Objektpunkte inklusive ihrer Koordinaten und Eigenschaften sein. Details dazu finden sich z. B. in Handbuch der Geodäsie: [Simultaneous Localization and Mapping](#) und den darin enthaltenen Referenzen.


---

## 3 Systemkalibrierung

Unabhängig davon, ob die Trajektorie der Plattform in Echtzeit oder im Postprocessing berechnet wird, ob sie nur Sensoren wie GNSS und Inertialsensoren oder auch die Objektraumsensoren wie Laserscanner und Kameras verwendet, ist die räumliche und zeitliche Zuordnung aller Beobachtungen, die von den Sensoren des Systems durchgeführt werden, eine wichtige Voraussetzung für den Betrieb von Multisensorsystemen. Da fehlerhafte Zuordnungen sich als systematische Abweichungen im Endprodukt des Mobile-Mapping-Vorgangs (z. B. einer Punktwolke) äußern, wird die Herstellung dieser Zuordnung, insbesondere der räumlichen, meist Systemkalibrierung genannt. Die Kalibrierung der Einzelsensoren, also die Bestimmung sensorinterner systematischer Abweichungen, wie z. B. die Zielachs- und Kippachsabweichung beim Laserscanner, wird üblicherweise mit gesonderten Verfahren, eventuell sogar schon vom Hersteller, bestimmt und soll hier nicht weiter betrachtet werden. Im Folgenden wird ein kurzer Überblick über Verfahren zur räumlichen Zuordnung aller Beobachtung gegeben (Abschn. 3.1), dann werden Möglichkeiten zur zeitlichen Zuordnung vorgestellt (Abschn. 3.2).

### 3.1 Räumliche Kalibrierung

Bei der räumlichen Kalibrierung wird, wie in Abb. 7 links dargestellt, die Transformation (Rotation und Translation) eines jeden einzelnen Sensors bezüglich eines gemeinsamen Plattformkoordinatensystems bestimmt. Dabei können auch



**Abb. 7** Kalibrierung, räumliche und zeitliche Zuordnung der Sensordaten

Subgruppen von Sensoren getrennt kalibriert werden. So würde man z. B. zwei Kameras zu einem Stereokamerasystem und GNSS und Inertialsensoren zu einem GPS/IMU System zusammenfassen.

Die Relevanz der Kalibrierung ist leicht ersichtlich, wenn man sich klarmacht, dass z. B. eine kleine Rotation eines Laserscanners oder einer Kamera von  $1^\circ$  zu einer Positionsabweichung von fast 2 % der Objektentfernung führt. Die etwa 10 m vom Fahrzeug entfernt stehenden Fassaden würden dann mit einer systematische Abweichung von fast 20 cm verortet.

Es gibt zahlreiche Arbeiten über die Kalibrierung von Multisensorsystemen. Ein guter Überblick ist z. B. in Lichti & Skaloud [31] gegeben. Bei der Kalibrierung zwischen einem Laserscanner und dem Plattformsystem werden meist Referenzgeometrien mit dem Scanner beobachtet, die im Plattformsystem bekannt sind. Letzteres lässt sich zum Beispiel erreichen, indem die Referenzobjekte und die Plattform mit einem Messgerät in einem übergeordneten System eingemessen werden [32]. Als Objekte eignen sich vor allem Dinge, deren Form sich leicht parametrisieren lässt. Die meisten Kalibrierverfahren arbeiten daher mit Ebenen. Die Kalibrierung von Kameras funktioniert in einer ähnlichen Weise, die Kamera beobachtet Punkte, Linien oder Flächen, die im Plattformsystem bekannt sind. Der Aufwand dieser „Laborverfahren“ ist jedoch sehr hoch.

Es gibt andere Verfahren [33], mit denen nur aus der Form (z. B. Ebene) von beobachteten Objekten, ohne Wissen über deren Position und Orientierung zumindest einige der Kalibrierparameter bestimmt werden können. Als Referenzobjekte dienen dann die Objekte, die sowieso während des eigentlichen Betriebs aufgenommen werden (z. B. Wände oder Dächer). Die relative Transformation zwischen Laserscannern und Kameras lässt sich auch während des normalen Betriebs bestimmen, in dem markante Objekte, wie z. B. Kanten, in den Beobachtungen beider Sensoren gefunden werden. Auch hier ist die Kenntniss über die absolute Position und Orientierung der Objekte nicht notwendig.

### 3.2 Synchronisierung der Sensordaten

Eine weitere wichtige Aufgabe ist die Synchronisierung der Sensordaten. Das Ziel der Synchronisierung ist es, wie in Abb. 7 illustriert, jede Beobachtung so mit einem Zeitstempel zu versehen, dass alle Sensoren die gleiche Zeitbasis haben. Wie sich eine Synchronisierungsabweichung zwischen der Georeferenzierung und der Kamera oder dem Laserscanner auswirkt, hängt von der Geschwindigkeit der Plattform ab. Eine unberücksichtigte Verzögerung von einer Millisekunde führt bei Schrittgeschwindigkeit zu einer Abweichung von einem Millimeter und bei einer Geschwindigkeit von 100 km/h zu knapp drei Zentimetern. Ebenfalls wichtig ist die Synchronisierung aller zur Trajektorienbestimmung eingesetzten Sensoren, da diese ja korrekt miteinander fusioniert werden müssen. Das ist bei unterschiedlichen Messverfahren, die auch noch variable zeitliche Berechnungszeiten benötigen können, insbesondere für den Echtzeitbetrieb eine große Herausforderung.

Ein Grund für die Schwierigkeit der Synchronisierung liegt in den vielen unterschiedlichen Messprinzipien und Schnittstellen der einzelnen Sensoren. Einige Sensoren führen auf Basis eines angelegten Signals (Trigger) eine Messung durch, so dass diese Beobachtung recht einfach der Zeitbasis des signalauslösenden Systems zugeordnet werden kann. Manche Sensoren (z. B. Kompaktkameras) benötigen allerdings nach dem Trigger noch eine unbestimmte und variable Zeit bis zur eigentlichen Messung, so dass eine exakte Synchronisierung nahezu unmöglich ist. Einige Sensoren führen ihre Messung zwar ungetriggert aus (z. B. mit einer bestimmten Frequenz, die durch eine eigene Uhr vorgegeben ist), erzeugen aber zum Zeitpunkt ihrer Messung ein Signal, was wiederum von einem anderen System zur Generierung eines Zeitstempels verwendet werden kann. Viele Profillaserscanner stellen ein Signal zur Verfügung, welches bei jedem „Nulldurchgang“ geschaltet wird. Die Zuordnung der einzelnen Distanzmessung während einer Rotation erfolgt dann durch Interpolation bei Annahme einer konstanten Rotationsgeschwindigkeit des Spiegels. Nahezu unmöglich ist eine exakte Synchronisierung, wenn der Beobachtungszeitpunkt nur durch die Ankunft der Sensordaten im PC bestimmt werden kann. Die Verwendung serieller Schnittstellen wie USB und die Benutzung von nicht echtzeitfähigen Betriebssystemen erzeugen zu viele unbekannte und variable Zeitverzögerungen zwischen dem Beobachtungszeitpunkt und dem Dateneingang.

Ein ideales System zur Synchronisierung mehrerer Sensorsysteme hat also folgende Eigenschaften:

1. Es hat eine Uhr, die über die Zeit sehr stabil ist oder regelmäßig mit Hilfe eines Frequenznormals synchronisiert wird.
2. Es ist in der Lage, zu definierten Zeitpunkten Signale zu erzeugen, die zum Auslösen von anderen Sensoren genutzt werden können.
3. Es ist in der Lage, Signale von anderen Sensoren zu empfangen und den genauen Zeitpunkt des Empfangs (z. B. die steigende Flanke des Signals) zu bestimmen und zu speichern.

Die Rolle des in Punkt 1 genannten Frequenznormals wird bei mobilen Multi-sensorsystem häufig durch das GPS eingenommen. Die meisten GPS-Empfänger stellen ein sog. PPS-Signal (Pulse-Per-Second) zur Verfügung, welches zum einen eine sehr genaue Zeitmessung erlaubt und zum anderen die Zeitbasis definiert, auf die sich die GPS Beobachtungen beziehen. Punkt 2 und 3 können nur mit Systemen realisiert werden, die zeitdeterministisch arbeiten und einen direkten Zugriff auf einzelne Signalleitungen bieten. Das ist zum Beispiel mit bestimmten Eingabe/Ausgabe-Modulen (IO-Boards) möglich, auf denen Echtzeitbetriebssysteme laufen. Ein solches Modul wurde im folgenden Beispiel eingesetzt.

---

## 4 Der „Mapping on Demand“ Oktokopter– Ein fliegendes Multisensorsystem

Zum Schluss soll beispielhaft ein mobiles Multisensorsystem vorgestellt werden, in dem die meisten in diesem Kapitel beschriebenen Verfahren unter besonderen Bedingungen zum Einsatz kommen. Bei dem System handelt es sich um ein leichtes<sup>8</sup> unbemanntes Flugobjekt (UAV: Unmanned Aerial Vehicle), welches innerhalb des Forschungsprojektes „Mapping on Demand“<sup>9</sup> entwickelt wurde, und welches zum Ziel hat, schwer zugängliche Objekte mit Hilfe von Bildinformationen aus der Luft zu vermessen. Eine große Herausforderung spiegelt sich dabei in dem Namenszusatz „on Demand“ wider. Neben der Aufgabe der 3D-Geometrierekonstruktion aus Kameradaten soll das UAV vollständig autonom fliegen können, dabei Hindernisse eigenständig erkennen und die aufgenommenen Bilddaten in Echtzeit prozessieren sowie semantische Informationen daraus extrahieren. Eine genaue Positions- und Orientierungsbestimmung des UAVs in Echtzeit ist daher nicht nur für die direkte Georeferenzierung der Bilddaten, sondern auch für die autonome Navigation des Objektes notwendig.


### 4.1 Sensoren

Das Fluggerät mit all seinen Komponenten ist in Abb. 8 dargestellt. Es handelt sich um einen sog. Oktokopter mit acht Rotoren, von denen jeweils zwei übereinander angeordnet sind, um einen kompakteren Aufbau zu ermöglichen und rotorfreie und somit vibrationsarme Ausleger für Sensoren zu ermöglichen. Es enthält einen kleinen leistungsfähigen Computer, auf dem hauptsächlich Algorithmen zur Bildverarbeitung und zur autonomen Navigation durchgeführt werden. Über eine WLAN-Schnittstelle wird der ständige Kontakt mit einer Bodenstation gehalten. Auf die autonome Steuerung des Fluggerätes soll hier nicht weiter eingegangen werden. Informationen dazu finden sich in Dröschel et al. [34].

---

<sup>8</sup> leichter als 5 kg, das entspricht dem Gewicht, bis zudem in Deutschland unbemannte Fluggeräte unter vereinfachten rechtlichen Bedingungen betrieben werden dürfen.

<sup>9</sup> durch die DFG gefördert als Forschergruppe FOR1505 (von 2012 bis 2017).



**Abb. 8** Aufbau des innerhalb des Projektes „Mapping on Demand“ entwickelten Fluggerätes

Auf dem System befindet sich eine Einheit zur direkten Georeferenzierung, welche in der Lage ist, die Trajektorie des Fluggerätes mit Hilfe von zwei GNSS-Empfängern, einer MEMS-basierten Inertialsensoreinheit und einem Magnetfeldsensor in Echtzeit zu bestimmen und gleichzeitig für die Synchronisierung aller Sensorbeobachtungen zuständig ist. Diese Einheit und die darauf laufenden Algorithmen werden im nächsten Abschnitt genauer beschrieben.

Weiterhin enthält das System zwei Stereokamera Paare, die nach vorne und nach hinten mit einem Winkel von  $45^\circ$  schräg nach unten schauen. Durch die Verwendung von Fisheye-Objektiven haben die Linsen einen Öffnungswinkel von etwa  $180^\circ$ , so dass der gesamte Bereich in der Ebene und unter dem Fluggerät beobachtet werden kann. Mit Methoden der visuellen Odometrie (Abschn. 2.2.3) werden aus den Bildern in Echtzeit Informationen über die Bewegung des Flugobjektes berechnet und zusammen mit den GNSS-Beobachtungen und den Inertialsensordaten zu einer Trajektorie verrechnet [35]. Gleichzeitig werden die in diesem Prozess generierten Objektpunkte zur Hindernisvermeidung verwendet.

Eine Fünf-Megapixel-Kamera wird für die eigentliche Beobachtung des Objektraumes eingesetzt. Aus ihren Bildern werden mit Hilfe verschiedener Verfahren dichte Punktwolken oder Oberflächenkarten berechnet. Diese werden, abhängig vom verwendeten Verfahren, in Echtzeit oder im Postprocessing erstellt, sind mit Hilfe der in diesem Abschnitt beschriebenen Methoden georeferenziert und stellen das eigentliche Ergebnis des Mobile-Mapping-Vorgangs dar.

## 4.2 Synchronisierte Auslese und Verarbeitung der Sensordaten

Die oben erwähnte Einheit zur Georeferenzierung ist das Herzstück des Multisensorsystems. Sie wurde innerhalb des Projektes entwickelt, um die besonderen Herausforderungen, die sich durch die fliegende Plattform und die Anwendungsum-

gebung ergeben, zu bewältigen. Sie enthält einen Zwei-Frequenz-GPS-Empfänger zur Berechnung einer präzisen RTK (Realtime Kinematic) GPS-Lösung, einen Ein-Frequenz-GPS-Empfänger, der mit seiner Antenne und der des anderen Empfängers eine kurze lokale Basislinie auf dem Fluggerät bildet, die zur Orientierungsbestimmung benutzt werden kann, sowie eine MEMS-basierte Inertialsensoreinheit, die auch einen dreiachsigen Magnetfeldsensor enthält. Außerdem ist ein Funkmodem verbaut, mit dem die für die RTK-Berechnung notwendigen Korrekturdaten einer Referenzstation empfangen werden können.

Der Prozessierungsteil der Einheit basiert auf einem Prozessor mit einem Echtzeitbetriebssystem und einem FPGA (Field Programmable Gate Array). Letzteres ermöglicht eine besonders schnelle Auslese und Vorverarbeitung aller Sensordaten, insbesondere wenn die Sensoren über eine serielle Schnittstelle kommunizieren. Es ist außerdem in der Lage, die interne Uhr mit Hilfe des vom GNSS-Empfänger bereitgestellten PPS-Signals zu synchronisieren und stellt somit, wie in Abschn. 3.2 beschrieben, die Zeitbasis für das Multisensorsystem zur Verfügung. Die zwei Stereokamera-paare und der hochaufgelöste Sensor werden durch ein von dieser Einheit erzeugtes Signal ausgelöst und die aufgenommenen Bilder so mit den restlichen Daten synchronisiert. Die Verwendung eines Echtzeitbetriebssystems ermöglicht die Implementierung der Auslese, Vorverarbeitung und Weiterverarbeitung der Sensordaten innerhalb zeitdeterministisch ablaufender Prozesse verschiedener Frequenzen und sorgt dafür, dass die Berechnungsergebnisse eindeutig bestimmten Zeitpunkten zuzuordnen sind und somit auch für eine Regelung des Fluggerätes einsetzbar sind.

Tab. 2 zeigt die Messraten verschiedener Sensoren und Messverfahren, die bei dem vorgestellten Multisensorsystem zum Einsatz kommen. Außerdem sind Latenzen der Verfahren dargestellt. Dabei handelt es sich hier um die Zeit zwischen der Gültigkeit der Daten und der Verfügbarkeit der Daten für eine Berechnung oder im Falle abgeleiteter Größen am Ende einer Berechnung. Die Latenzen der einzelnen Verfahren sind größtenteils variabel, aber begrenzt und durch die gemeinsame Zeitbasis bekannt. In den Algorithmen können diese dann korrekt berücksichtigt werden und zu einer Positions- und Orientierungsinformation verarbeitet werden, die immer die gleiche Latenz und damit einen konsistenten Zeitbezug liefert.

**Tab. 2** Messraten und Latenzen verschiedener Messverfahren in dem vorgestellten System

Sensoren + Messverfahren	Messrate	Latenz
Inertialsensoren, Magnetfeldsensoren	100 Hz	< 1 ms
Ein-Frequenz- und Zwei-Frequenz-GNSS-Beobachtungen	10 Hz	< 30 ms
Korrekturdaten über Funkmodem	2 Hz	~ 50–500 ms
RTK-GPS Positionsbestimmung	10 Hz	< 100 ms
Ein-Frequenz-Basislinienauswertung	1 Hz	< 100 ms
Positions- und Orientierungsänderungen aus visueller Odometrie	10 Hz	< 100 ms
Genauere Positions- und Orientierungsänderungen aus gleitender Bündelausgleichung	0–1 Hz	~ 1–10 s
→ <b>Geschätzte Position und Orientierung aus Kalman-Filter</b>	<b>100 Hz</b>	<b>= 10 ms</b>



### 4.3 Algorithmen zur Trajektorienbestimmung

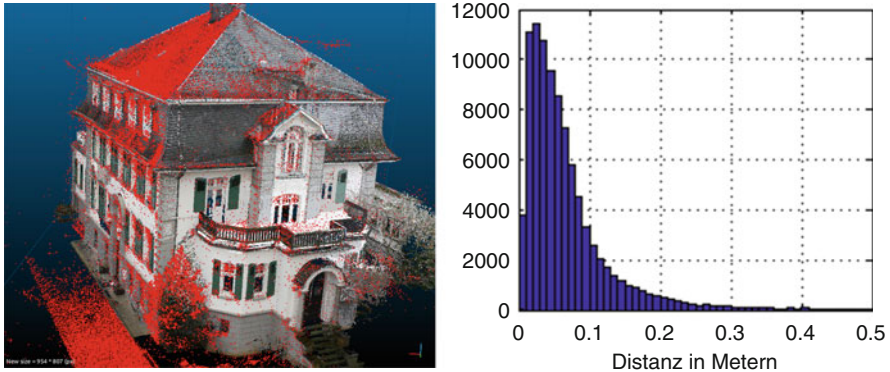
Auf eine detaillierte Vorstellung der Algorithmen zur Trajektorienbestimmung soll hier verzichtet werden. Dazu sei auf Eling et al. [36] verwiesen. Bezug nehmend auf Abschn. 2.4 werden hier jedoch einige Aspekte der Kalman-Filterung vorgestellt.

Der Zustandsvektor des Filters für die Trajektorienbestimmung enthält die Position und Geschwindigkeit der Plattform, ihre Orientierung, sowie die Offsets der Drehraten- und der Beschleunigungssensoren. Letztere werden aufgrund ihres zeitlichen Verhaltens wie in Abschn. 2.4.2 beschrieben mitgeschätzt und als Random-Walk-Prozess mit kleiner Varianz modelliert. Die Modellierung der Plattformbewegung geschieht mit Hilfe der Inertialnavigation (Abschn. 2.2.1). Aus den Beobachtungen der Inertialsensoren werden die relativen Änderungen von Orientierung, Geschwindigkeit und Position berechnet und über Stellgrößen ins Systemmodell eingebracht. Dabei wird aufgrund der lokalen Begrenztheit der Trajektorie und des vergleichsweise hohen Rauschens der Drehratensensoren der Einfluss der Transportrate und der Erddrehrate vernachlässigt.

Die in das Filter eingebrachten Beobachtungen sind die Position aus dem 2-Frequenz-Empfänger, dem Basislinienvektor zwischen den beiden Antennen sowie der Vektor des Erdmagnetfeldes. Die GNSS-Auswertung, also im Wesentlichen die Auflösung der Trägerphasenmehrdeutigkeiten (Abschn. 2.3.1) geschieht in diesem als „lose gekoppelte Integration“ bezeichneten Verfahren außerhalb des Kalman-Filters. Im Gegensatz dazu gehen bei der komplexeren „eng gekoppelten Integration“ die Trägerphasen direkt als Beobachtungen in das Filter ein, wodurch es z. B. prinzipiell möglich ist, mit Satellitenkonstellationen zu rechnen, die weniger als vier Satelliten enthalten. Im Fall der „losen Kopplung“ muss, wenn zu wenig Satelliten und damit keine Positionsinformationen zur Verfügung stehen, das Systemmodell geändert werden, da die Position bei reiner Inertialnavigation schnell wegdreift. Daher wird in dieser Zeit nur die Orientierung der Plattform geschätzt, wobei die Beobachtung des Erdmagnetfeldvektors die Drift der Drehratensensoren verringert. Die Schätzung des Beschleunigungssensorbias wird dann allerdings ebenfalls ausgesetzt, da dieser aufgrund fehlender Redundanzen nicht mehr beobachtbar ist.

### 4.4 Ergebnis

Abb. 9 zeigt beispielhaft die Qualität einer Punktwolke, die mit dem fliegenden Multisensorsystem erzeugt wurde. Die roten Punkte sind die georeferenzierten Objektpunkte nach einer Bündelausgleichung (Abschn. 2.3.3), in die, neben den Bildern, auch die mit den in diesem Kapitel beschriebenen Verfahren während des Fluges berechneten Positionen und Orientierungen der Kamera zu den Auslösezeitpunkten eingehen. Die Punkte sind im Vergleich zu einem georeferenzierten terrestrisch aufgenommenen Laserscan dargestellt. Rechts sieht man die Abstände zwischen dem Ergebnis des Multisensorsystems und des terrestrischen Scanners in



**Abb. 9** Vergleich einer georeferenzierten Punktwolke mit einem Terrestrischen Laserscan. Mit freundlicher Genehmigung von Johannes Schneider, Universität Bonn

einer Histogrammdarstellung, wobei hier jeweils die Differenz zum nächsten Nachbarn berechnet wurde. Der Median der absoluten Abweichung beträgt etwa 3 cm.

## Literatur

1. Kraus, K.: Photogrammetrie Band 1 – Geometrische Informationen aus Photographien und Laserscanner-aufnahmen, 7. Aufl. Walter de Gruyter, Berlin/New York (2004)
2. Heister, H., Caspary, W., Hock, C., Klemm, J., Sternberg, H.: Kiss, a hybrid measuring system for kinematic surveying. In: Linkwitz, K., Hangleiter, U. (Hrsg.) High Precision Navigation 95, Proceedings, Ferd. S. 561–568. Dümmler Verlag, Bonn (1995)
3. Gräfe, G., Caspary, W., Heister, H., Klemm, J., Sever, M.: The road data acquisition system MoSES determination and accuracy of trajectory data gained with the applanix POS/LV. In: Proceedings 3rd International Symposium on Mobile-Mapping Technology, Cairo (2001)
4. Talaya, J., Alamus, R., Bosch, E., Serra, A., Kornus, W., Baron, A.: Integration of a terrestrial laser scanner with GPS/IMU orientation sensors. In: Proceedings of XXth ISPRS Congress, Commission 5, Istanbul (2004)
5. El-Sheimy, N., Lavigne, M.: 3D gis data acquisition using gps/ins/video mobile-mapping system. In: Proceedings Geodesy for Geotechnical and Structural Engineering, Eisenstadt, S. 375–380 (1998)
6. Gilliéron, P.Y., Skaloud, J., Brugger, D., Merminod, B.: Development of a low cost mobile-mapping system for road data base management. In: The 3rd International Symposium on Mobile-Mapping Technology, Cairo (2001)
7. Grejner-Brzezinska, D., Toth, C., Xiao, Q.: Real-time tracking of highway linear features. In: Proceedings of the ION GPS, Salt Lake City (2000)
8. Puente, I., González-Jorge, H., Martínez-Sánchez, J., Arias, P.: Review of mobile-mapping and surveying technologies. Measurement **46**(7), 2127–2145 (2013)
9. Klingbeil, L., Lottes, P., Kuhlmann, H.: Laserscanning-technologie auf sich bewegendem plattformen. In: Schriftenreihe des DVW, Terrestrisches Laserscanning 2014 (TLS 2014), Bd. 78, S. 19–29. Wißner Verlag, Fulda (2014)
10. Wirth, H., Brüggemann, T.: The development of a multiple transducer multi-beam echo sounder system for very shallow waters, Proceedings FIG working week „bridging the gap between cultures“, Marrakech Morocco, 18.22.05.2011

11. Kuhlmann, H., Wieland, M.: Steering of a seeding process with a multi-sensors system. In: FIG Working Week, Rome, S. 6–10 (2012)
12. Stachniss, C.: *Robotic Mapping and Exploration*, Bd. 55. Springer, Berlin (2009)
13. Titterton, D., Weston, J.: *Strapdown Inertial Navigation Technology*, 2. Aufl. The American Institute of Aeronautics and Astronautics, Reston (2004)
14. Wendel, J.: *Integrierte Navigationssysteme – Sensordatenfusion, GPS und Inertiale Navigation*. Oldenbourg, München (2007)
15. El-Sheimy, N., Hou, H., Niu, X.: Analysis and modeling of inertial sensors using allan variance. *IEEE Trans. Instrum. Meas.* **57**, 140–149 (2008)
16. Lowe, D.: Object recognition from local scale-invariant features. In: *Proceedings of the International Conference on Computer Vision*, Corfu Island, Bd. 2, S. 1150–1157 (1999)
17. Scaramuzza, D., Fraundorfer, F.: Visual odometry: Part I – the first 30 years and fundamentals. *IEEE Robot.* **18**(4), 80–92 (2011)
18. Besl, P.J., McKay, N.: A method for registration of 3-D shapes. *IEEE Trans. Pattern Anal. Mach. Intell.* **14**(2), 239–256 (1992)
19. Lu, F., Milios, E.: Robot pose estimation in unknown environments by matching 2D range scans. *J. Intell. Robot. Syst.* **18**(3), 249–275 (1997)
20. Hofmann-Wellenhof, B., Lichtenegger, H., Waskle, E.: *GNSS – Global Navigation Satellite Systems*. Springer, Wien/New York (2008)
21. Eling, C., Zeimet, P., Kuhlmann, H.: Development of an instantaneous GNSS/MEMS attitude determination system. *GPS Solut.* **17**(1), 129–138 (2013). doi:10.1007/s10291-012-0266-8. <http://dx.doi.org/10.1007/s10291-012-0266-8>
22. Klingbeil, L., Eling, C., Zimmermann, F., Kuhlmann, H.: Magnetic field sensor calibration for attitude determination. *J. Appl. Geod.* **8**(2), 97–108. ISSN (Online) 1862-9024, ISSN (Print) 1862-9016, doi:10.1515/jag-2014-0003 (2014)
23. Schneider, J., Laebe, T., Förstner, W.: Incremental real-time bundle adjustment for multi-camera systems with points at infinity. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **XL-1/W2**, 355–360 (2013)
24. Czommer, R.: *Leistungsfähigkeit fahrzeugautonomer ortungsverfahren auf der basis von map-matching-techniken*. Ph.D. thesis, Universität Stuttgart, Institut für Anwendungen der Geodäsie im Bauwesen (IAGB) (2000)
25. Julier, S.J., Uhlmann, J.K., Durrant-Whyte, H.F.: A new approach for filtering nonlinear systems. In: *Proceedings of the 1995 American Control Conference*, Seattle, S. 1628–1632 (1995)
26. Li, L., Kuhlmann, H.: Real-time deformation measurements using time series of gps coordinates processed by kalman filter with shaping filter. *Surv. Rev.* **44**(326), 189–197 (2012)
27. Heunecke, O., Kuhlmann, H., Welsch, W., Eichhorn, A., Neuner, H.: Auswertung geodätischer Überwachungsmessungen. In: Möser, M., Müller, G., Schlemmer, H. (Hrsg.) *Handbuch Ingenieurgeodäsie*, 2. Aufl. Wichmann, Heidelberg (2013)
28. Heunecke, O.: *Zur Identifikation und Verifikation von Deformationsprozessen mittels adaptiver KALMAN-Filterung (Hannoversches Filter)*. Ph.D. thesis, Wissenschaftliche Arbeiten der Fachrichtung Vermessungswesen der Universität Hannover, Heft 208 (1995)
29. Bloom, H.A.P.: An efficient filter for abruptly changing systems. In: *Proceedings of the 23rd IEEE Conference on Decision and Control*, Las Vegas, S. 656–658 (1984)
30. Thrun, S., Burgard, W., Fox, D.: *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents)*. The MIT Press, Cambridge (2005)
31. Lichti, D., Skaloud, J.: Registration and calibration. In: Vosselman, G., Maas, H.G. (Hrsg.) *In Airborne and Terrestrial Laser Scanning*. Whittles Publishing, Caithness (2010)
32. Strübing, T., Neumann, I.: Positions- und orientierungsschätzung von lidarsensoren auf multisensorplattformen. *Zeitschrift für Vermessungswesen* **3/2013**, 210–221 (2013)
33. Skaloud, J., Lichti, D.: Rigorous approach to bore-sight self-calibration in airborne laser scanning. *ISPRS J. Photogramm. Remote Sens.* **61**, 47–59 (2006)
34. Droschel, D., Nieuwenhuisen, M., Beul, M., Behnke, S.: Autonomous Navigation for Micro Aerial Vehicles in Complex GNSS-denied Environments *Journal of Intelligent & Robotic Systems*, 2015, 1-18, published online, DOI: 10.1007/s10846-015-0274-3

- 
35. Schneider, J., Förstner, W.: Real-time accurate geo-localization of a mav with omnidirectional visual odometry and Gps. In: Jawahar, C.V., Shiguang, S. (Hrsg.) *Computer Vision – ECCV 2014 Workshops*, S. 271–282. Springer International Publishing, Cham (2015)
  36. Eling, C., Klingbeil, L., Wieland, M., Kuhlmann, H.: Direct georeferencing of micro aerial vehicles – system design, system calibration and first evaluation tests. *PFG – Photogramm. Fernerkund. Geoinf.* **4**, 227–237 (2014)