

# Rekursive Bayesische Schätzverfahren zur Lokalisierung von Personen innerhalb von Gebäuden

Lasse Klingbeil und Michailas Romanovas

## Zusammenfassung

Der Beitrag beschreibt einige Arbeiten der Autoren im Bereich Lokalisierung von Personen innerhalb von Gebäuden. Es werden verschiedene Varianten rekursiver Bayesischer Schätzverfahren vorgestellt, mit denen sich die Daten verschiedener Sensoren und anderer Informationen wie Karten fusionieren lassen, um eine möglichst robuste Positionsschätzung zu ermöglichen. Es wird ein modulares Sensorsystem vorgestellt, welches den Aufbau und die Evaluierung verschiedener Kombinationen von Sensoren als Lokalisierungssystem ermöglicht. Abschließend werden beispielhaft die Ergebnisse zweier Kombinationen vorgestellt.

## Summary

*The report describes the work of the authors in the area of indoor localization. It describes the general concept of recursive Bayesian estimation algorithms, which are used to fuse data from various sensors and other information, such as maps of the environment, in order to achieve a robust localization method. A modular sensor system is presented, which enables a flexible setup and evaluation of multi sensor systems for pedestrian localization. Two examples are presented, which use (a) inertial sensors, radio range data and GPS and (b) inertial sensors only.*

**Schlüsselwörter:** Rekursive Bayesische Schätzung, Kalman-Filter, Personenlokalisierung, Inertialsensoren, Sensorfusion

## 1 Einleitung

Systeme zur Lokalisierung von Personen, insbesondere im Innenbereich von Gebäuden, sind seit einigen Jahren ein beliebtes Forschungsthema, was vermutlich unter Anderem dadurch begründet ist, dass ein äquivalentes System zu GNSS hinsichtlich Verfügbarkeit, Robustheit und Preis für den Innenbereich immer noch nicht absehbar ist. Das zeigt sich auch in zahlreichen nationalen und internationalen Förderprogrammen in den Bereichen Gesundheit und Altersversorgung (Varshney 2007) (z.B. Patiententracking, Überwachung von Demenzkranken) und im Bereich Sicherheit (z.B. Lokalisierung von Einsatzkräften (Klann 2009), Sicherheit im Untertagebau (Chehri et al. 2009)).

Es gibt zahlreiche Lokalisierungsmethoden wie Inertialnavigation, Multilateration oder -angulation mit Funk oder akustischen Signalen und optische Methoden wie Bildverarbeitung oder Laserscanning (ein Überblick findet sich z.B. in Hightower und Borriello 2001). Die meis-

ten dieser Methoden bieten allerdings nur für spezielle Anwendungen oder unter bestimmten Bedingungen zufriedenstellende Ergebnisse. Es gibt zwei Herausforderungen bei der Lokalisierung von Personen in Innenräumen, die durch die Faktoren »Innen« und »Personen« gegeben sind. Eine direkte Integration von Inertialsensoren zur Positionsbestimmung ist problematisch, da zum einen die komplexe Dynamik der menschlichen Bewegung schwer zu modellieren ist, und zum anderen die Integration der Sensordaten schnell zu großen Abweichungen führt. Weiterhin sollten die Systeme tragbar sein, wodurch z.B. Laserscanner, wie sie in der Robotik erfolgreich eingesetzt werden (Thrun et al. 2005), nur eine untergeordnete Rolle spielen. Die Umgebung innerhalb von Gebäuden führt außerdem dazu, dass man bei Verwendung funkbasierter und akustischer Verfahren verstärkt mit Signalstörungen wie Mehrwegausbreitung zu kämpfen hat.

In der vorliegenden Arbeit wird der Ansatz verfolgt, dass ein robustes und zuverlässiges Verfahren zur Lokalisierung im Innenbereich nicht nur auf einer einzigen Sensorkomponente basieren darf, sondern mehrere möglichst komplementäre Sensormodalitäten vereinen sollte. Weiterhin sollten Bewegungsmodelle und zusätzliche Informationen wie Kartenmaterial in die Schätzung der Position eingebunden werden. Algorithmisch kann eine solche Aufgabenstellung durch rekursive Bayesische Schätzverfahren realisiert werden, von denen die üblichsten Varianten im Folgenden vorgestellt werden. Danach wird ein Überblick gegeben, welche Sensoren und Informationen zur Lokalisierung von Personen eingesetzt werden können und auf welche Weise diese in einen Schätzalgorithmus eingebunden werden können. Es wird ein von den Autoren entwickeltes modulares Sensorsystem vorgestellt, mit dem es möglich ist, verschiedene Sensoren zur Lokalisierung flexibel miteinander zu verbinden, und schließlich werden beispielhaft zwei mit diesem System realisierte Lokalisierungsanwendungen, die dafür entwickelten Schätzalgorithmen und die Ergebnisse der Positionsbestimmung vorgestellt.

## 2 Rekursive Bayesische Schätzverfahren

Rekursive Bayesische Schätzverfahren werden häufig (Thrun et al. 2005) zur Schätzung des Zustandes  $x_k$  eines dynamischen Systems zu einem Zeitpunkt  $t_k$  unter Berücksichtigung aller Messungen  $Z_k = \{z_0, \dots, z_k\}$  bis zu diesem Zeitpunkt verwendet. Die aktuelle Schätzung des Zustandes wird als Wahrscheinlichkeitsdichtefunktion

$p(\mathbf{x}_k | z_0, \dots, z_k)$  repräsentiert, die mit Hilfe von »Bayes Rule« berechnet werden kann:

$$p(\mathbf{x}_k | Z_k) = \frac{p(Z_k | \mathbf{x}_k) p(\mathbf{x}_k)}{p(Z_k)}. \quad (1)$$

Unter der Annahme, dass die Messungen  $\{z_0, \dots, z_k\}$  statistisch unabhängig sind, lässt sich Gl. 1 in eine rekursive Formel umstellen:

$$p(\mathbf{x}_k | Z_k) = \frac{p(z_k | \mathbf{x}_k) p(\mathbf{x}_k | Z_{k-1})}{p(z_k | Z_{k-1})}. \quad (2)$$

Der Term  $p(z_k | Z_{k-1})$  ist dabei ein Normalisierungsfaktor. Der Term  $p(\mathbf{x}_k | Z_k)$  wird A Posteriori Wahrscheinlichkeit genannt und beschreibt die aktuelle Zustandsschätzung basierend auf allen bisherigen Messungen. Der Term

$$p(\mathbf{x}_k | Z_{k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | Z_{k-1}) d\mathbf{x}_{k-1} \quad (3)$$

wird A Priori Wahrscheinlichkeit genannt und beschreibt die aktuelle Schätzung auf Basis aller bisherigen Messungen außer der aktuellen. Die A Priori Wahrscheinlichkeit beinhaltet die A Posteriori Schätzung  $p(\mathbf{x}_{k-1} | Z_{k-1})$  zum letzten Zeitpunkt  $t_{k-1}$  und den Term  $p(\mathbf{x}_k | \mathbf{x}_{k-1})$ , der das sogenannte Prozessmodell enthält, welches das Vorwissen über die Systemdynamik und die dazugehörige Unsicherheit des Modells beschreibt. Der Term  $p(z_k | \mathbf{x}_k)$  repräsentiert das *Messmodell* und beschreibt die Relation zwischen den Beobachtungen des Systems und dem Systemzustand sowie die Ungenauigkeiten dieser Messungen. Mit obigen Gleichungen lässt sich jede Aktualisierung der rekursiven Bayesischen Schätzung in zwei Schritte unterteilen, die üblicherweise beim Auftreten neuer Beobachtungen durchgeführt werden.

#### Vorhersage:

Die A Priori Wahrscheinlichkeit der aktuellen Schätzung wird mit Hilfe des Prozessmodells aus der A Posteriori Wahrscheinlichkeit der letzten Schätzung berechnet (Gl. 3).

#### Korrektur:

Die A Posteriori Wahrscheinlichkeit der aktuellen Schätzung wird mit Hilfe des Messmodells und den aktuellen Beobachtungen aus der A Priori Wahrscheinlichkeit der aktuellen Schätzung berechnet (Gl. 2).

Es gibt eine Reihe von Implementationen rekursiver Bayesischer Schätzverfahren, die sich im Wesentlichen durch die Art und Weise unterscheiden, wie die Wahrscheinlichkeiten repräsentiert sind und wie diese durch die Prozess- und Messmodelle transformiert werden. Wenn die Modelle linear sind und die Wahrscheinlichkeiten, also die Unsicherheiten der Modelle, normalverteilt sind, ist das Kalman-Filter (KF) eine effiziente und im Sinne der kleinsten Quadrate Schätzung optimale Lösung. Bei nichtlinearen Modellen kann das *Unscented Kalman-*

*Filter* (UKF) (Julier et al. 2000) oder das *Erweiterte (Extended) Kalman-Filter* (EKF) verwendet werden. Beim EKF werden die Modelle mit Hilfe von Jacobi Matrizen linearisiert, wohingegen beim UKF die Wahrscheinlichkeitsverteilungen durch eine Reihe von deterministisch berechneten Stützpunkten (*Sigmapunkte*) repräsentiert werden, die die ersten beiden Momente der Verteilung unter nichtlinearen Transformationen weitestgehend beibehalten. Bei sequentiellen Monte Carlo Filtern, wie dem *Partikel-Filter* (PF), werden die Wahrscheinlichkeiten durch eine Anzahl von Stichproben repräsentiert, die aus der jeweiligen Verteilung gezogen werden.

Im Folgenden werden die Formeln für das KF, EKF, UKF sowie für das PF kurz skizziert. Ein detaillierter Überblick über die verschiedenen Filter und deren Einsatz zur Positionsbestimmung sowie eine Herleitung der Algorithmen findet sich z.B. in Thrun et al. (2005).

#### Kalman-Filter

Beim Kalman-Filter wird die Schätzung des aktuellen Zustands  $\mathbf{x}_k$  durch den Mittelwert  $\hat{\mathbf{x}}_k$  und die Kovarianz  $P_k$  einer als normal angenommenen Wahrscheinlichkeitsverteilung

$$p(\mathbf{x}_k) = \mathcal{N}(\mathbf{x}_k; \hat{\mathbf{x}}_k, P_k) \quad (4)$$

repräsentiert. Die Gleichungen für das Prozess- und das Messmodell sind im Allgemeinen

$$\begin{aligned} \mathbf{x}_k &= f(\mathbf{x}_{k-1}, \mathbf{u}_k, \mathbf{w}_k), \\ \mathbf{z}_k &= h(\mathbf{x}_k, \epsilon_k), \end{aligned} \quad (5)$$

wobei  $\mathbf{u}_k$  eine Stellgröße des Systems ist, und  $\mathbf{w}_k$  und  $\epsilon_k$  Zufallsvariablen sind, die Modellunsicherheiten bzw. Messabweichungen repräsentieren. Sind die Funktionen  $f$  und  $h$  linear in  $\mathbf{x}$ ,  $\mathbf{u}$ ,  $\mathbf{w}$  und  $\epsilon$ , wird Gl. 5 zu

$$\begin{aligned} \mathbf{x}_k &= A_k \mathbf{x}_{k-1} + B_k \mathbf{u}_k + \mathbf{w}_k, \\ \mathbf{z}_k &= H_k \mathbf{x}_k + \epsilon_k, \end{aligned} \quad (6)$$

und die rekursive Schätzung lässt sich mittels der bekannten Kalman-Filter-Gleichungen durchführen:

#### Vorhersage:

$$\begin{aligned} \tilde{\mathbf{x}}_k &= A_k \mathbf{x}_{k-1} + B_k \mathbf{u}_k, \\ \tilde{P}_k &= A_k P_{k-1} A_k^T + Q_k, \end{aligned} \quad (7)$$

#### Korrektur:

$$\begin{aligned} K_k &= \tilde{P}_k H_k^T (H_k \tilde{P}_k H_k^T + R_k)^{-1}, \\ \mathbf{x}_k &= \tilde{\mathbf{x}}_k + K_k (z_k - H_k \tilde{\mathbf{x}}_k), \\ P_k &= (I - K_k H_k) \tilde{P}_k. \end{aligned} \quad (8)$$

Dabei sind  $Q_k$  und  $R_k$  die Kovarianzen des Prozess- und Messrauschen.

## Extended Kalman-Filter

Der Extended Kalman-Filter eignet sich für Anwendungen, in denen die Funktionen  $f(\cdot)$  und  $h(\cdot)$  in Gl. 5 nicht linear sind. In diesem Falle werden zur Fortpflanzung der Kovarianzen die Funktionen mit Hilfe einer Taylorentwicklung um den Punkt der letzten Schätzung, bzw. der aktuellen Vorhersage, linearisiert:

$$A_k = \frac{\partial f}{\partial \mathbf{x}} \Big|_{\mathbf{x}_{k-1}, \mathbf{u}_k}, \quad H_k = \frac{\partial h}{\partial \mathbf{x}} \Big|_{\tilde{\mathbf{x}}_k}. \quad (9)$$

Ähnliche Matrizen müssen bei Nichtlinearitäten der Funktionen  $f(\cdot)$  und  $h(\cdot)$  bezüglich der Stellgrößen  $\mathbf{u}$  und des Rauschens  $\mathbf{w}$  bzw.  $\epsilon$  aufgestellt werden. Mit diesen können dann die Gl. 7 und Gl. 8 zur rekursiven Schätzung durchgeführt werden.

## Unscented Kalman-Filter

Beim EKF kann es (abhängig von der Nichtlinearität der Modelle) aufgrund der Linearisierung zu Ungenauigkeiten kommen. Dieses Problem kann durch die Verwendung eines UKF umgangen werden. Dabei wird die aktuelle Zustandsschätzung inklusive ihrer Kovarianz durch eine Menge von  $2n+1$  Sigmabalken repräsentiert:

$$\mathbf{x}_k, P_k \Rightarrow \{\mathcal{X}_i\}, \quad i = 1 \dots 2n+1, \quad (10)$$

wobei  $n$  die Dimension des Zustandsvektors ist (in anderen Varianten des UKF kann die Zahl der Sigmabalken unter bestimmten Annahmen weiter reduziert werden). Diese Punkte werden dann an den entsprechenden Stellen im Vorhersage- und Korrekturschritt mit Hilfe der im Allgemeinen nichtlinearen Funktionen  $f$  und  $h$  transformiert. Daraufhin werden der Mittelwert und die Kovarianz der transformierten Wahrscheinlichkeitsdichte aus

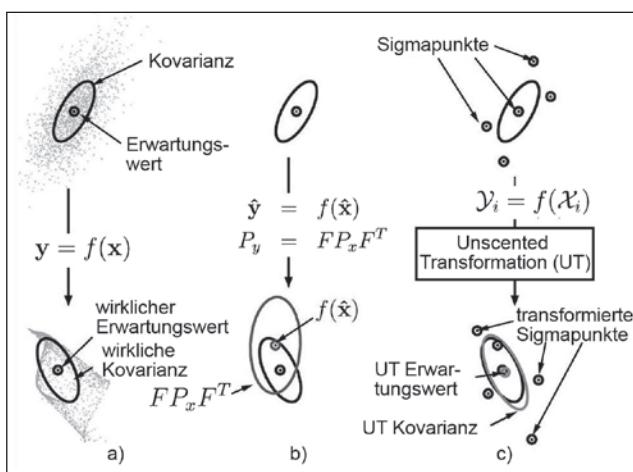


Abb. 1: Vergleich einer nichtlinearen Wahrscheinlichkeitstransformation beim Extended und Unscented Kalman-Filter. Durch eine lokal linearisierte Transformation (EKF) können Verzerrungen auftreten, die durch die Verwendung eines UKF umgangen werden können (nach Haykin 2001).

den transformierten Sigmabalken zurückgerechnet. Die Gleichungen für Vorhersage und Korrektur sind dann im Wesentlichen sehr ähnlich zu Gl. 7 und Gl. 8, auf eine detaillierte Beschreibung des Algorithmus sowie des Verfahrens zur Berechnung der Sigmabalken und der Rekonstruktion von Mittelwert und Kovarianz wird an dieser Stelle verzichtet. Dazu sei auf Julier et al. (2000) verwiesen.

## Partikel-Filter

Das Partikel-Filter verwendet die Methode des Sequentiellen Importance Samplings, bei der die gesuchte A Posteriori Wahrscheinlichkeitsdichte durch eine größere Menge ( $\sim 1000$ ) von gewichteten zufälligen Stichproben  $(\mathbf{x}^{[i]}, w^{[i]}), i = 1, \dots, N$  (Samples oder Partikel) approximiert wird:

$$p(\mathbf{x}) \approx \sum_i w^{[i]} \delta(\mathbf{x} - \mathbf{x}^{[i]}), \quad (11)$$

dabei ist  $\delta(\mathbf{x})$  die Dirac'sche Delta Funktion. Die Partikel werden mit Hilfe einer Ersatzdichteverteilung generiert und die Gewichte  $w^{[i]}$  werden unter Einbeziehung der Beobachtungen rekursiv ständig neu berechnet. Zusätzlich werden in einem Resampling-Schritt Partikel mit geringem Gewicht eliminiert und neue Partikel in Bereichen höherer Wahrscheinlichkeit erzeugt.

Es gibt eine Vielzahl verschiedener Varianten des Partikel-Filters, die sich hauptsächlich in der Wahl der Ersatzdichte Verteilung sowie der Art und Häufigkeit des Resampling-Schrittes unterscheiden. Hier soll aus Gründen der Anschaulichkeit lediglich die weitverbreitete Variante des Sample Importance Resample Partikel-Filters (SIR-PF) vorgestellt werden, bei dem als Ersatzverteilung das Prozessmodell  $p(\mathbf{x}_k | \mathbf{x}_{k-1})$  selbst gewählt wird, und ein Resampling-Schritt in jedem Zyklus durchgeführt wird. Diese Variante wird auch in den später beschriebenen Beispielen eingesetzt und zeichnet sich durch eine vergleichsweise einfache Implementierung aus. Eine ausführliche Beschreibung der Theorie hinter dem Partikel-Filter und ein Überblick über die verschiedenen Varianten finden sich z.B. in Chen (2003).

### Vorhersage:

Jedes Sample  $(\mathbf{x}_{k-1}^{[i]}, w_{k-1}^{[i]})$  der letzten Schätzung  $p(\mathbf{x}_{k-1})$  wird durch ein neues Sample ersetzt, welches mit Hilfe der Funktion  $f$  in Gl. 5 berechnet wird, sodass eine neue Menge von Samples  $(\tilde{\mathbf{x}}_k^{[i]}, \tilde{w}_k^{[i]})$  entsteht, die der A Priori Wahrscheinlichkeit, bzw. im Gauss'schen Fall  $(\tilde{\mathbf{x}}_k, \tilde{P}_k)$  entspricht.

### Korrektur:

Mit Hilfe des Messmodells  $h$  in Gl. 5 werden nun aus den Samples der A Priori Wahrscheinlichkeit Messungen vorhergesagt, die dann mit den tatsächlichen Beobachtungen  $\mathbf{z}_k$  verglichen werden. Anhand dieses Vergleichs und unter Berücksichtigung des Messrauschens werden

die Gewichte der Samples neu berechnet, sodass die Samples mit ihren neuen Gewichten

$$w_k^{[i]} \propto p(z_k | x_k^{[i]}), \quad \sum_i w_k^{[i]} = 1. \quad (12)$$

der A Posteriori Wahrscheinlichkeit entsprechen.

#### Resampling:

In diesem zusätzlichen Schritt im Partikel-Filter wird eine neue Menge Samples erzeugt, die der Wahrscheinlichkeitsverteilung nach dem Korrekturschritt entspricht, bei der aber die Gewichte wieder alle den gleichen Wert bekommen. Auf diese Weise werden unwahrscheinliche Samples eliminiert und neue Samples in Regionen höherer Wahrscheinlichkeit erzeugt.

Ein wesentlicher Vorteil des Partikel-Filters gegenüber den vorgestellten Kalman-Filter-Konzepten ist, dass es damit möglich ist, multimodale Wahrscheinlichkeiten zu modellieren. Die Kalman-Filter gehen von einer unimodalen Gauss'schen bzw. annähernd Gauss'schen Verteilung aus. 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 sonst gleichen Sensordaten und Anfangsbedingungen zu leicht unterschiedlichen Ergebnissen führt (s. Abb. 6). Dieser Effekt ist größer, je kleiner die Anzahl der verwendeten Samples ist.

### 3 Sensoren

Die Herausforderung bei der Entwicklung und Implementierung von Filteralgorithmen ist die Formulierung der Prozess- und Messmodelle, die natürlich stark von der Art der verwendeten Sensoren abhängt. Im Folgenden sind – ohne Anspruch auf Vollständigkeit – eine Reihe von Sensoren zur Lokalisierung und ihre Möglichkeiten der Einbindung in die Algorithmen aufgelistet. Die Lokalisierung von Personen innerhalb von Gebäuden wird dabei als Hauptanwendung betrachtet. An dieser Stelle sollte erwähnt werden, dass ein Sensor nicht notwendigerweise im Korrekturschritt eines rekursiven Schätzverfahrens eingebunden werden muss. Insbesondere Sensoren für relative oder inkrementelle Messgrößen, wie Drehratensensoren oder Geschwindigkeitsmesser, können als Stellgröße im Vorhersageschritt eingebunden werden. Auf diese Weise kann die Formulierung eines Bewegungsmodells, in dem z.B. eine konstante Geschwindig-

keit oder eine konstante Beschleunigung angenommen werden muss, umgangen werden. Das ist insbesondere bei der Lokalisierung von Personen förderlich, die sich im Allgemeinen ungleichmäßig und schwer vorhersagbar bewegen.

**Inertialsensoren:** Inertialsensoren (Beschleunigungs- und Drehratensensoren) können auf verschiedene Weise in ein Lokalisierungssystem eingebunden werden. Generell lässt sich mit ihnen die Orientierung eines Objektes im Raum bestimmen (Romanovas et al. 2009) (meist zusammen mit Magnetfeldsensoren). Mit Hilfe der Orientierung lässt sich die gravitative Beschleunigungskomponente bestimmen, um so die bewegungsrelevante translatorische Beschleunigung zu erhalten. Mit Hilfe von Inertialsensoren ist es auch möglich, menschliche Bewegungszustände wie »Gehen«, »Stehen«, »Laufen« zu erkennen (Parkka et al. 2006), auf deren Basis dann z.B. Parameter des Algorithmus dynamisch angepasst werden können. Außerdem lassen sich die Schrittänge und Schrittzahl (Lee und Mase 2002) bestimmen, was wiederum als Stellgröße in den Algorithmus einfließen kann.

**Magnetfeldsensoren:** Mit Magnetfeldsensoren lässt sich der Vektor des Erdmagnetfeldes bestimmen, um die inertialsensorbasierte Orientierungsbestimmung zu stützen. Innerhalb von Gebäuden ist das Erdmagnetfeld jedoch meist signifikant gestört, was in den Algorithmen entsprechend zu berücksichtigen ist.

**Distanzmessungen:** Distanzmessungen zwischen dem zu lokalisierenden Objekt und bekannten oder unbekannten Positionen der Umgebung können z.B. mit Ultraschallsendern (Hazaras und Hopper 2006), Laserscannern, Funkwellen oder Time-Of-Flight-Kameras (Prusak et al. 2008) durchgeführt werden. Funkbasierte Verfahren beinhalten Ultra-Wideband-Ranging (Segura et al. 2009, Guoping und Rao 2005), Chirp Spread Spectrum Modulation (Neuwinger et al. 2009) und Abstandsschätzung basierend auf der empfangenen Signalstärke (Received Signal Strength, RSS) beliebiger Funksignale (Paul und Wan 2009, Mazuelas et al. 2009). Einzelne Abstandsmessungen oder auch aus mehreren Abständen berechnete Positionen (Multiilateration) können im Korrekturschritt des Algorithmus eingebunden werden.

**GNSS-Empfänger:** Ein GNSS-Empfänger liefert die Position und Geschwindigkeit eines Objektes, die als direkte Beobachtung des Zustandes in den Korrekturschritt des Algorithmus eingebunden werden können. Streng genommen kann der Empfänger auch als Distanzsensor zur vorherigen Kategorie gezählt werden, falls die Pseudoranges direkt in das Filter eingehen (Tightly-Coupled Integration). Innerhalb von Gebäuden sind GNSS-Empfänger aufgrund von Signalabschwächung und Mehrwegausbreitung nur bedingt geeignet.

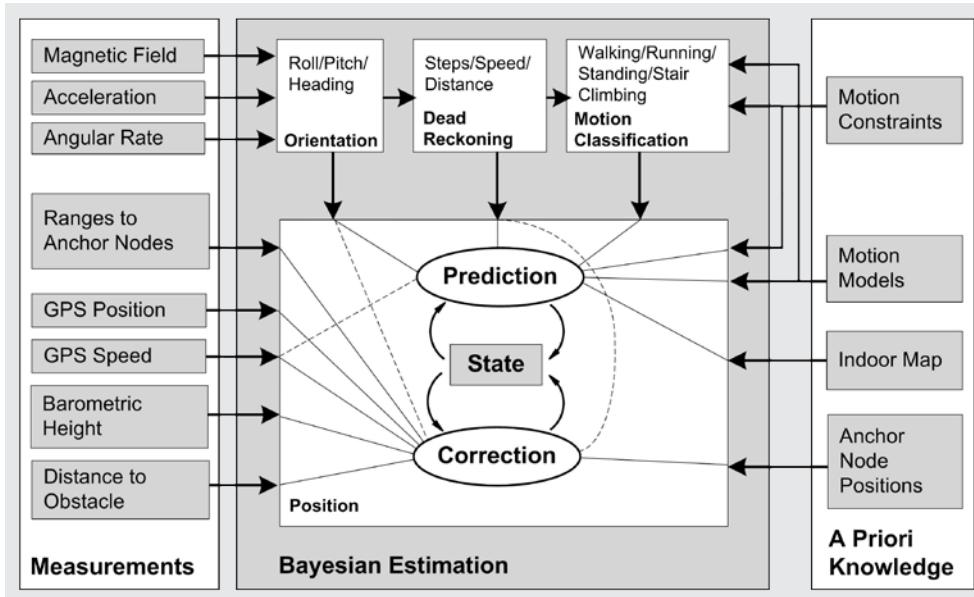


Abb. 2: Beispiele von Möglichkeiten zur Einbindung von Sensordaten und zusätzlichen Informationen in einen rekursiven Bayesischen Schätzalgorithmus zur Positionsbestimmung

**Drucksensoren:** Drucksensoren, als Barometer verwendet, können die vertikale Position eines Objektes schätzen und ermöglichen so eine direkte Beobachtung einer Zustandsvariablen im Korrekturschritt des Algorithmus.

**Kameras:** Mit Kameras, die am bewegten Objekt befestigt sind, lassen sich mit verschiedenen Methoden Informationen über die relative Bewegung oder die Position des Objektes generieren. In den Arbeiten der Autoren und in den später beschriebenen Beispielen spielen sie jedoch keine Rolle, weshalb hier auf eine detailliertere Beschreibung verzichtet wird. Informationen dazu finden sich z.B. in Nister et al. (2004) oder Wolf et al. (2005).

**Karteninformationen:** Karten beinhalten Informationen über die Umgebung, in der das Objekt lokalisiert wird. Im einfachsten Fall könnte eine Karte lediglich die Positionen von Ankerpunkten enthalten, zu denen Distanzmessungen vom bewegten Objekt erfolgen (ähnlich dem GPS-Almanach, der die Positionen der Satelliten enthält). Karten können aber auch Informationen über besetzte und freie Flächen enthalten, sodass eine Bewegung auf freie »begehbar« Flächen eingeschränkt werden kann (Belegungskarte). Karten können auch das Signalstärkeprofil der Umgebung in Bezug auf ein vorhandenes Funknetzwerk (Takenga und Kyamakya 2007) beschreiben oder sie beinhalten Positionen von Merkmalen der Umgebung, die mit Kameras oder Laserscannern erfasst werden. Letztere werden häufig auch als Teil des Zustandsvektors behandelt, um diese zur Laufzeit des Filters zu schätzen (*Simultaneous Localization and Mapping*, SLAM (Thrun et al. 2005)).

Alle hier beschriebenen Sensoren wurden bereits in Systemen zur Lokalisierung verwendet. Der von den Autoren verfolgte Ansatz besteht darin, sie alle gleichzeitig

zu benutzen. Das allein mag nicht sehr sinnvoll erscheinen, aber ein System, in dem beliebige Sensoren modular miteinander kombiniert werden können (sowohl bezüglich der Hardware als auch der Algorithmen), eröffnet zahlreiche Möglichkeiten zur Untersuchung, Entwicklung und Evaluierung von Lokalisierungssystemen für unterschiedliche Anwendungen. Abb. 2 fasst schematisch zusammen, wie die oben beschriebenen Sensordaten und andere Informationen in einen rekursiven Bayesischen Schätzalgorithmus

modular eingebunden werden können.

Eine mathematische Formulierung der Fusion der unterschiedlichen Sensordaten wird an dieser Stelle explizit nicht vorgenommen. Es soll vielmehr die Flexibilität und Modularität des Verfahrens der Rekursiven Bayesischen Schätzung, mit besonderem Augenmerk auf die Lokalisierung von Personen, demonstriert werden. Die konkrete Implementierung hängt stark vom Sensorsystem, der Spezifikation der Anwendung und der Wahl des Filters ab. Zwei Beispiele dafür werden im nächsten Kapitel beschrieben.

## 4 Beispiele

Abb. 3 zeigt das Konzept und den aktuellen Status eines Sensorsystems, in dem verschiedene Platinen mit unterschiedlichen Funktionalitäten (z.B. Energieversorgung, Kommunikation, Distanzmessung, Inertialsensorik) je nach Bedarf aufeinandergesteckt werden können, um ein anwendungsspezifisches Lokalisierungssystem aufzubauen. Im Folgenden werden zwei Beispiele aufgezeigt, in denen mit diesem System zwei unterschiedliche Konzepte zur Personenlokalisierung umgesetzt wurden.

### 4.1 Partikel-Filter mit Schrittdetektion, Distanzmessungen, GPS und Karte

In diesem Beispiel wird die Position einer Person mit Hilfe von Inertial- und Magnetfeldsensoren, funkbasierten Distanzmessungen und einem GPS-Empfänger bestimmt (eine ausführlichere Beschreibung dieser Anwendung findet sich in Klingbeil et al. 2010). Ein Sensorsystem, wie in Abb. 3 dargestellt, wird dazu an der Hüfte der

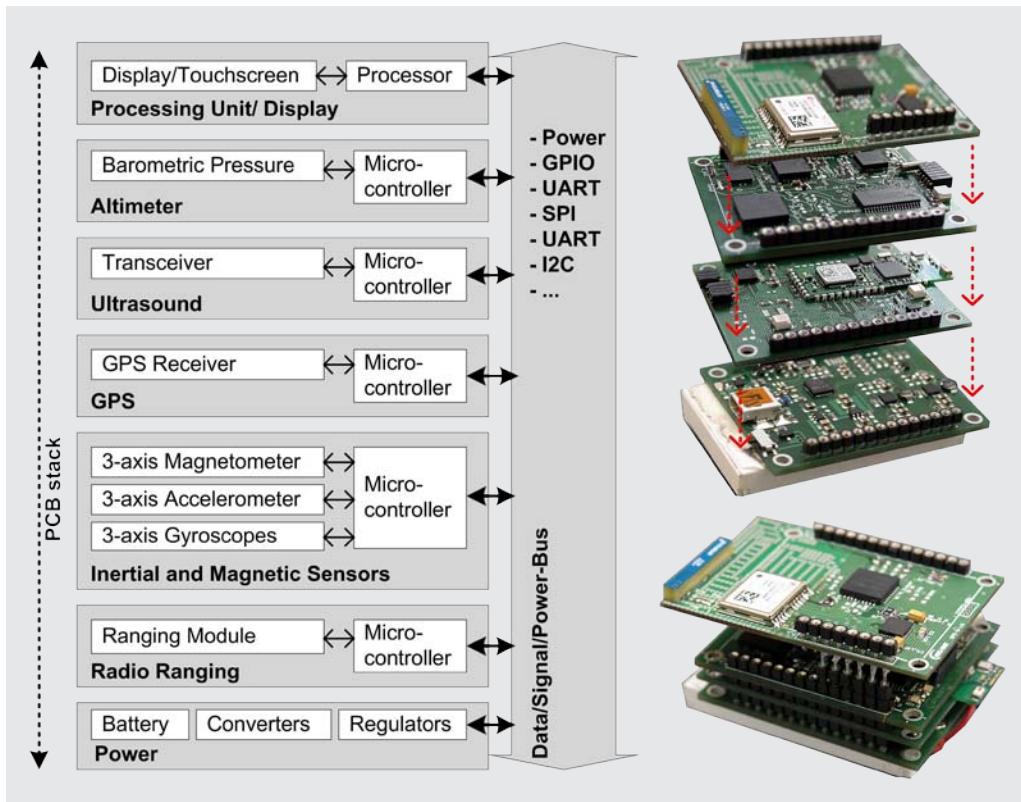


Abb. 3:  
Konzept und Realisierung der in den Beispielen verwendeten Hardware zur Lokalisierung von Personen

Person befestigt. Weitere Sensorknoten befinden sich an georeferenzierten Positionen innerhalb des Gebäudes wie in Abb. 4 dargestellt. Zwischen diesen Knoten und dem bewegten System werden laufend Distanzmessungen durchgeführt. Außerhalb des Gebäudes stehen dem bewegten Sensorknoten außerdem GPS-Daten zur Verfügung.

#### Vorhersage:

Der Zustandsvektor des Partikel-Filters besteht aus der zweidimensionalen Position  $\mathbf{x}_k = [x_1 \ x_2]^T$  der Person. Die aktuelle Schätzung wird, wie in Abschnitt 2 beschrieben, durch eine Menge von Samples repräsentiert (im vorliegenden Beispiel wurde eine Anzahl von  $N = 1000$  Partikeln gewählt). Im Vorhersageschritt werden die Samples

mit Hilfe der Schrittlänge  $l$  und der Bewegungsrichtung  $\phi$  als Stellgrößen transformiert:

$$\begin{aligned} \mathbf{x}_k &= f(\mathbf{x}_{k-1}, \mathbf{u}_k) \\ \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}_k^{[i]} &= \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}_{k-1}^{[i]} + l_k^{[i]} \begin{pmatrix} \sin(\phi_k^{[i]}) \\ \cos(\phi_k^{[i]}) \end{pmatrix}. \end{aligned} \quad (13)$$

Die Stellgröße  $\mathbf{u} = [l \ \phi]^T$  ist ebenfalls eine Wahrscheinlichkeitsverteilung, also als Menge von Samples modelliert:

$$\begin{aligned} \hat{l}_k^{[i]} &= l_k + n_l^{[i]}, \quad n_l^{[i]} \sim p(n_l) = \mathcal{N}(n_l; 0, \sigma_l) \\ \phi_k^{[i]} &= h_k + n_\phi^{[i]}, \quad n_\phi^{[i]} \sim p(n_\phi) = \mathcal{N}(n_\phi; 0, \sigma_\phi). \end{aligned} \quad (14)$$

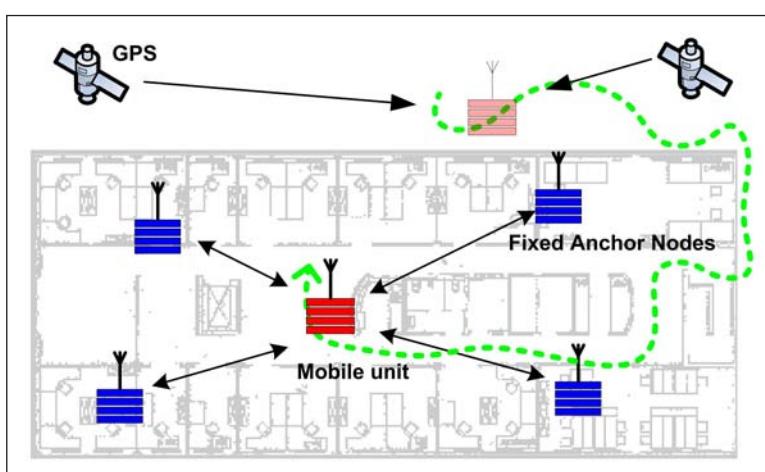


Abb. 4: Aufbau des im ersten Beispiel demonstrierten Lokalisierungssystems

$l_k$  und  $\phi_k$  sind die Messungen der Schrittlänge und der Bewegungsrichtung. Als Stellgrößenunsicherheit wird eine Normalverteilung mit vergleichsweise hohen Varianzwerten  $\sigma_l, \sigma_\phi$  angenommen (im vorliegenden Beispiel wurden  $\sigma_l = 0.3\text{m}$  und  $\sigma_\phi = 25^\circ$  gewählt).

Ein Vorhersageschritt geschieht immer bei der Detektion eines Schrittes und daher zu unregelmäßigen Zeitabständen. Die Schritte werden mit Hilfe eines Schwellwert-basierten Verfahrens detektiert, das auf die Länge des gemessenen Beschleunigungsvektors angewendet wird. Die Schrittlänge wird ebenfalls aus den Daten des Beschleunigungssensors extrahiert (Weinberg 2002). Die Bewegungsrichtung wird mit Hilfe eines EKF aus den

Drehratensensoren und den Magnetfeldsensoren berechnet. Das Filter wird dabei so eingestellt, dass die innerhalb von Gebäuden stark gestörten Magnetfelddaten nur einen geringen Einfluss auf die geschätzte Richtung haben, aber dennoch die Drift der Drehratensensoren kompensieren.

#### Karteninformation:

Innerhalb des Vorhersageschrittes wird auch die Karteninformation in den Algorithmus einbezogen. In diesem Beispiel wird eine Belegungskarte verwendet, bei der die Umgebung als Matrix repräsentiert wird, in der jeder Eintrag für einen  $10\text{ cm} \times 10\text{ cm}$  großen Bereich steht (s. Abb. 5). Der Eintrag »0« steht für »frei« und eine »1« steht für »besetzt«.

Für jedes Sample wird nun überprüft, ob das in der Vorhersage berechnete Weginkrement  $\tilde{x}_k^{[i]} - x_{k-1}$  einen besetzten Bereich überquert. Falls ja, wird das zu dem entsprechenden Sample gehörende Gewicht  $w$  auf einen Wert  $\epsilon$  nahe 0 gesetzt, ansonsten bleibt es unberührt:

$$\tilde{w}_k^{[i]} = \begin{cases} w_{k-1}^{[i]}, & \text{freier Weg} \\ \delta \ll 1, & \text{belegten Bereich gekreuzt} \end{cases}. \quad (15)$$

Prinzipiell ließe sich das Gewicht in einem solchen Fall auch auf 0 setzen, was einem einfachen Löschen des Partikels entsprechen würde, ein kleiner Wert bietet jedoch einem Sample eine kleine Wahrscheinlichkeit durch Wände zu »tunneln«, wodurch verhindert werden kann,

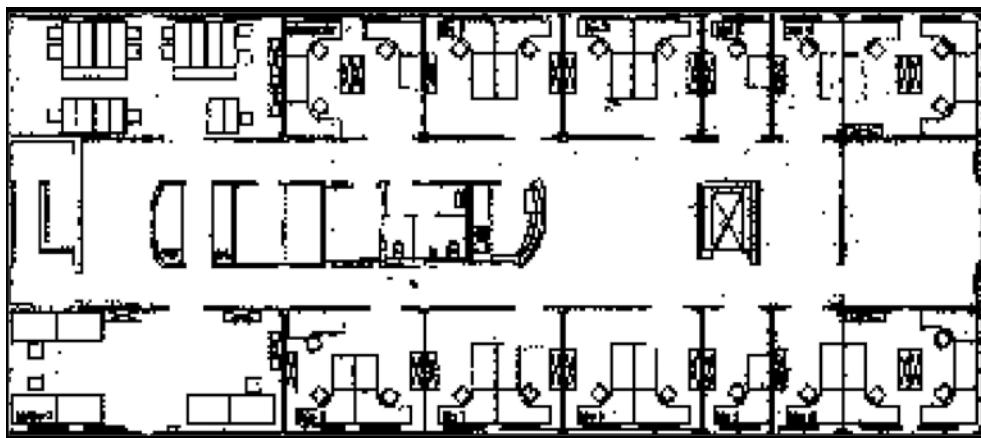


Abb. 5:  
Darstellung der Belegungskarte. Begehbarer Bereich ist weiß, nicht begehbarer Bereich ist schwarz dargestellt.



Abb. 6:  
Einfluss der Karteninformation auf die Schätzung.  
Oben: ohne Karte,  
unten: mit Karte

dass eine große Menge von Samples hinter einer Wand oder in einem Raum »gefangen« werden (im vorliegenden Beispiel wurde  $\delta = 10^{-5}$  gewählt).

Abb. 6 zeigt den Einfluss der Karte auf die Schätzung. Dargestellt sind jeweils zehn Durchläufe des Filters bei gleichen Sensordaten und Anfangsbedingungen, oben ohne und unten mit Einbindung der Karte im Vorhersageschritt. Man erkennt hier außerdem eine wichtige schon vorher erwähnte Eigenschaft des Partikel-Filters: die Ergebnisse der Schätzungen der verschiedenen Durchläufe sehen durch die im Filter verwendeten Sampling- und Resampling-Schritte jedes Mal ein wenig anders aus. Die geschätzte Position wurde als Mittelwert aller Partikel berechnet, wodurch auch die Kreuzung von Wänden trotz Verwendung der Karte erklärt wird.

#### Korrektur:

Im Korrekturschritt wird mit Hilfe von Messungen aus der A Priori Wahrscheinlichkeit die A Posteriori Wahrscheinlichkeit berechnet, dass heißt, die Gewichte  $\tilde{w}_k^{[i]}$  der Samples werden mit Hilfe der Likelihood  $p(z_k | \tilde{x}_k^{[i]})$  einer Messung bei gegebenen vorhergesagten Zustandssamples berechnet.

In diesem Beispiel werden zwei Arten von Messungen für den Korrekturschritt verwendet, nämlich eine Distanzmessung zu einem bekannten Punkt der Umgebung und eine Positionsmessung des GPS-Empfängers. Beide Messungen treten asynchron auf, dass heißt, es werden je nach »Art« der Messungen unterschiedliche Korrekturschritte durchgeführt.

Die Distanzmessungen werden mit einem Nanotron™ Funkmodul (Nanotron 2007) durchgeführt, mit dem auf Basis der Chirp Spread Spectrum Modulationstechnik die Entfernung zwischen Sender und Empfänger gemessen werden kann. Laut Hersteller liegt die dabei erreichte Genauigkeit unter idealen Bedingungen bei etwa einem Meter. Innerhalb von Gebäuden sind die Messungen allerdings wesentlich ungenauer. In Abb. 7 sieht man die

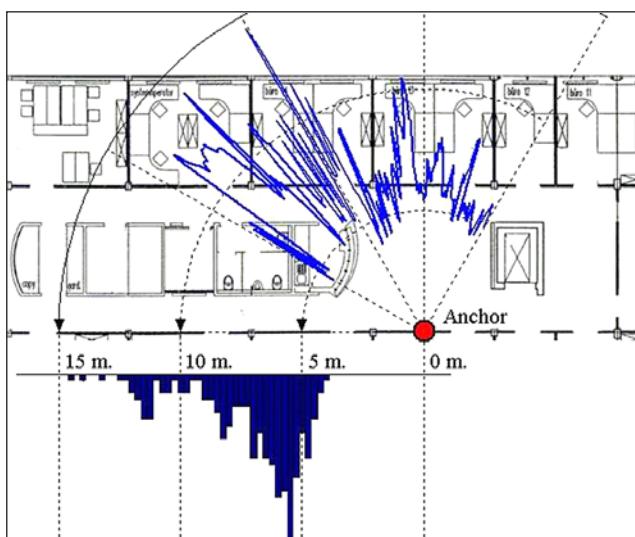


Abb. 7: Verteilung mehrerer Distanzmessungen bei gleichem Abstand in einer Büroumgebung

Verteilung mehrerer Distanzmessungen, die alle bei einem Abstand von 5 m bei freier Sichtbedingung durchgeführt wurden. Abgesehen von der Tatsache, dass hier höhere Abweichungen auftreten, ist besonders auffällig, dass die Verteilung der Abweichungen nicht normal verteilt, sondern stark asymmetrisch ist. Hauptsächlich durch Reflexionen der Signale innerhalb der Räume treten starke systematische Abweichungen auf.

Hier kommt ein Vorteil eines Partikel-Filters gegenüber den Kalman-Filter-Varianten zum Tragen. Die Messabweichung der Abstandsmessung kann durch eine beliebige nicht normale Verteilung modelliert werden. In diesem Fall wurde die asymmetrische logistische Funktion als Modell für die Abweichung gewählt

$$L(r; \mu, s) = \frac{e^{-(r-\mu)/s}}{s(1+e^{-(r-\mu)/s})^2}, \quad (16)$$

wobei die Asymmetrie durch verschiedene Werte des Parameters  $s$  für Werte größer oder kleiner des Mittelwerts  $\mu$  erreicht wird.

Nachdem eine Distanzmessung zwischen dem bewegten Objekt und einem festen Sensorknoten durchgeführt wurde, wird für jedes Sample  $\tilde{x}_k^{[i]}$  der A Priori Wahrscheinlichkeit sein Abstand  $\tilde{d}_{n,k}^{[i]} = X_n - \tilde{x}_k^{[i]}$  zur festen Position  $X_n$  berechnet und mit der Messung  $d_{n,k}$  verglichen:

$$p(z_k | x_k) = p(d_k | x_k, X_n) \propto \begin{cases} L(r; 0, s_1), & r \geq 0 \\ L(r; 0, s_2), & r < 0 \end{cases}, \quad (17)$$

wobei  $r = \tilde{d}_{n,k}^{[i]} - d_{n,k}$  ist und  $L(x; \mu, s)$  mit  $s_1 = 1\text{m}$  und  $s_2 = 0.5 \cdot \tilde{d}$  die asymmetrische logistische Funktion in Gl. 16.

Der GPS-Empfänger, ein ublox 5 NEO, misst die Position direkt, wobei eine normal verteilte Abweichung angenommen wird:

$$p(z_k | x_k) = p(x_k^{GPS} | x_k) \propto \mathcal{N}(r; 0, \sigma_{GPS}^2), \quad (18)$$

dabei ist  $r = |\tilde{x}_k - x_k^{GPS}|$  die Differenz zwischen der vorhergesagten Sampleposition und  $\mathcal{N}(r; \mu, s)$  die Normalverteilung (im vorliegenden Beispiel wurde vom GPS-Modul übertragene Positionsstandardabweichung als  $\sigma_{GPS}$  gewählt). Die Modellierung der Messabweichung als Normalverteilung ist streng genommen nicht korrekt, hat sich jedoch für die vorliegende Anwendung als ausreichend gezeigt. Eine bessere Modellierung wäre z.B. durch die Verwendung von Formfiltern gegeben (Kuhlmann 2003).

#### Messungen:

Die Ergebnisse einer beispielhaften Messung sind in Abb. 8 dargestellt. Eine Person, die das Sensorsystem vor die Brust gehängt hat, startet außerhalb des Gebäudes, geht nach etwa 110 Sekunden in das Gebäude, läuft dort für etwa eine Minute und verlässt das Haus danach wieder. Die grüne Linie zeigt in etwa den wirklich geläufenen Weg. Die roten Punkte sind die Messungen des

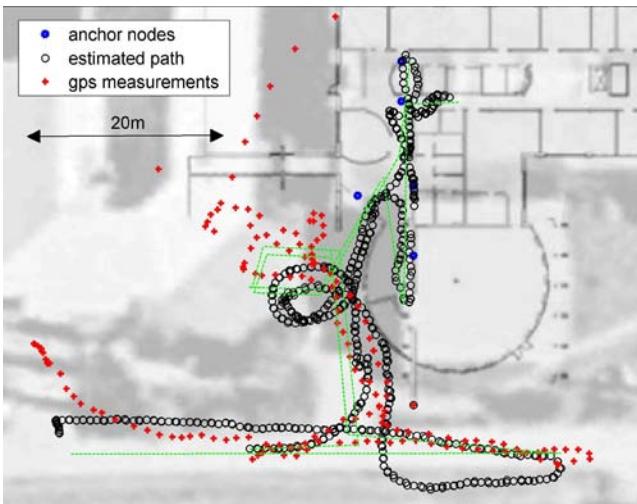


Abb. 8: Schätzung des gelaufenen Weges in einer gemischten Innen/Außen-Umgebung

GPS-Empfänger, die in der Nähe des Eingangs stark durch das Gebäude gestört sind, und die schwarzen Kreise zeigen das Ergebnis der Schätzung. Die blauen Punkte sind die Positionen der festen Sensorknoten im Gebäude.

#### 4.2 Unscented Kalman-Filter mit Inertialsensoren und Zero Velocity Updates

Ein alternativer Ansatz zur Lokalisierung von Personen, der ebenfalls mit dem modularen Systemaufbau auf Basis der bereits vorgestellten Algorithmen verfolgt wurde, wird im Folgenden vorgestellt. Hier werden lediglich Beschleunigungs- und Drehratensensoren verwendet, die

über die bekannten Gleichungen der Inertialnavigation (»Strapdown Integration«, siehe z.B. Titterton et al. 2004) direkt zu einer Positionsinformation integriert werden. Der wesentliche Punkt bei diesem Ansatz ist, dass die Sensoren am Fuß der Person befestigt werden, und dass die periodisch auftretenden Ruhezustände des Fußes beim Auftreten zur Korrektur des unvermeidlichen Drifts der Navigationslösung verwendet werden (Zero Velocity Updates, ZUPT (Foxlin 2005)).

#### Vorhersage:

Die Positionsschätzung geschieht mit Hilfe eines Unscented Kalman-Filters, dessen Zustandsvektor  $\mathbf{x}_k$  aus der aktuellen Orientierung  $\mathbf{q}_k$  als Quaternion, der Position  $\mathbf{p}_k$  und der Geschwindigkeit  $\mathbf{v}_k$  des Fußes besteht, sowie aus den Offsetwerten  $\mathbf{b}_{\omega,k}, \mathbf{b}_{a,k}$  der Drehraten- und Beschleunigungssensoren:

$$\mathbf{x}_k = [\mathbf{q}_k, \mathbf{v}_k, \mathbf{p}_k, \mathbf{b}_{\omega,k}, \mathbf{b}_{a,k}]^T. \quad (19)$$

Die Offsetwerte werden aus Mangel an weiteren Informationen als langsamer Random Walk modelliert. Die Daten der Inertialsensoren werden als Stellgrößen in das Prozessmodell eingebunden. Die Orientierung wird über einfache Integration aus den gemessenen Drehraten berechnet. Diese Orientierung wiederum wird verwendet, um aus den Daten der Beschleunigungssensoren die Gravitationskomponente zu extrahieren und aus der übrig gebliebenen translatorischen Beschleunigung über Integration die Geschwindigkeit und die Position des Fußes zu bestimmen.

Ein detaillierter schematischer Überblick über den Vorhersageschritt des Unscented Kalman-Filters ist in Abb. 9 gegeben. Auf eine mathematische Beschreibung wird hier verzichtet. Der Vorhersageschritt wird jeweils bei Auftreten neuer Inertialsensordaten durchgeführt, ohne dass notwendigerweise ein Korrekturschritt eingeschoben wird. Dieses würde bei vollständigem Ausbleiben der Korrekturen zu einer starken Divergenz der Positionslösung führen, da sich die Ungenauigkeiten der eingesetzten MEMS-Sensoren durch die Integration schnell aufaddieren. Daher werden zu bestimmten Zeitpunkten Korrekturschritte durchgeführt.

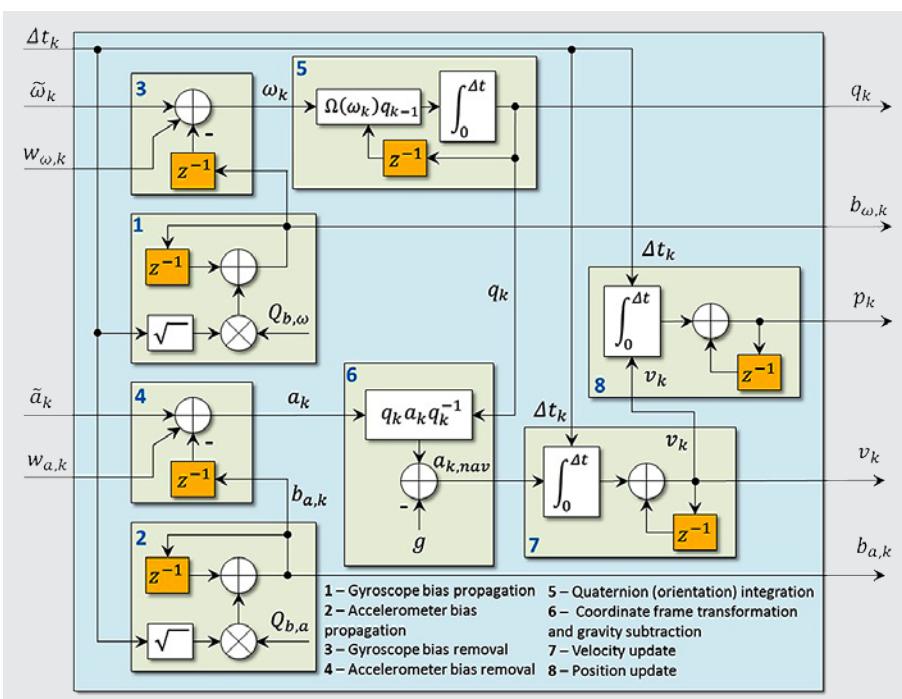


Abb. 9: Schematische Darstellung des Prozessmodells für den Unscented Kalman-Filter. Einen wesentlichen Bestandteil bildet dabei die Gleichung zur Strapdown Integration von Inertialsensoren.

**Korrektur:**

Es wird davon ausgegangen, dass sich der Fuß einer Person während des Gehens für kurze Momente in Ruhe befindet. Diese Momente werden mit unterschiedlichen, meist heuristischen schwellewertbasierten Algorithmen detektiert, um aus dem Wissen über den Systemzustand zu diesen Zeitpunkten virtuelle Messgrößen zu generieren, die dann über Messmodelle  $z_k = h(x_k; \epsilon_k)$  im Korrekturschritt in die Schätzung einbezogen werden:

1. Die Geschwindigkeit des Fußes zu einem Zeitpunkt ist Null (Zero Velocity Update, ZUPT)

$$[0 \ 0 \ 0]^T = v_k + \epsilon_{ZUPT,k}. \quad (20)$$

2. Die Daten der Drehratensensoren zu einem Zeitpunkt entsprechen dem Offset der Sensoren (Zero Angular Rate Update, ZARU)

$$\tilde{\omega}_k = b_{\omega,k} + \epsilon_{ZARU,k}. \quad (21)$$

3. Die einzige gemessene Beschleunigungskomponente zu einem Zeitpunkt ist durch die Gravitation (und die Offsets der Sensoren) gegeben, sodass Roll- und Nickwinkel des Fußes indirekt bestimmt werden können.

$$\tilde{a}_k = q_k^{-1} g_{\text{earth}} q_k + b_{a,k-1} + \epsilon_G. \quad (22)$$

$\epsilon_{ZUPT}, \epsilon_{ZARU}, \epsilon_G$  repräsentieren das Messrauschen für die verschiedenen Messungen,  $g_{\text{earth}}$  ist der Vektor der Gravitationsbeschleunigung. Während der Durchführung der wiederholten Vorhersageschritte werden die Drehraten- und Beschleunigungssignale ständig auf geeignete Bedingungen überprüft und im Falle eines Auftretens ein Korrekturschritt mit der oder den entsprechenden Messungen durchgeführt. Abb. 10 zeigt ein Blockdiagramm des rekursiven Schätzalgorithmus.

Es ist zu beachten, dass trotz der Korrekturen die Abweichungen in der Position und dem Gierwinkel der Schätzung immer noch ungebunden sind und stetig wachsen können. Sie tun das jedoch wesentlich langsamer (linear mit der Zeit) als ohne die Korrekturen. Außerdem

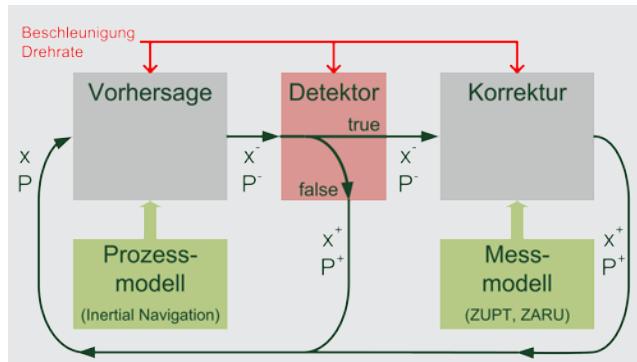


Abb. 10: Blockdiagramm des Algorithmus zur Positionsbestimmung mit Zero Velocity Updates. Der Detektorblock bestimmt, ob einer der Korrekturschritte durchgeführt wird oder nicht.

dem ist sowohl zur Positions- als auch zur Orientierungsbestimmung ein Initialwert notwendig, der entweder durch andere Sensoren oder Vorwissen ermittelt werden muss. An dieser Stelle lassen sich natürlich im Sinne der Modularität der Algorithmen weitere Sensoren wie Magnetfeldsensoren, GPS oder Barometer einbinden, um die eben genannten Schwierigkeiten zu umgehen.

**Messungen:**

Abb. 11 zeigt das Ergebnis der Positionsschätzung bei einem etwa sechs Minuten dauernden Spaziergang. Die rote gestrichelte Linie zeigt den wirklichen Pfad, die blaue und grüne Linie zeigen die Schätzungen mit dem vorgestellten Algorithmus. Dabei wurden zwei verschiedene



Abb. 11: Positionsschätzung bei einer etwa sechs Minuten dauernden Trajektorie. Die grüne und blaue Linie zeigen die auf Basis von zwei unterschiedlichen Sensorsystemen geschätzte Position, die gestrichelte rote Linie zeigt den wirklichen Pfad.

Inertialsensoreinheiten unterschiedlicher Qualität eingesetzt (blau: Verwendung einer kommerziell erhältlichen Inertialsensoreinheit mit temperaturkalibrierten Sensoren, grün: Verwendung des in Abb. 3 vorgestellten modularen Systems mit günstigen Sensoren).

Die Startposition und der Startgierwinkel wurden als bekannt angenommen. Auf eine Genauigkeitsanalyse wird aus Platzgründen verzichtet, man kann jedoch sehen, dass nach etwa sechs Minuten Gehen und zahlreichen Richtungswechseln die von beiden Systemen geschätzte Endposition nur wenige Meter von der wirklichen Position entfernt liegt. Man kann davon ausgehen, dass sich bei Einbindung weiterer absolut messender Sensoren langfristig die Position einer Person mit einer Genauigkeit bestimmen lässt, die für die meisten Anwendungen ausreicht.

Nur mit Hilfe von Inertialsensoren scheint die Genauigkeit dieser Methode bereits besser als die des in Abschnitt 4.1 beschriebenen Systems. Es ist jedoch zu bedenken, dass es für die Verwendung von Zero Velocity

Updates absolut notwendig ist, dass sich die Sensoren am Fuß der Person befinden. Je nach Anwendung ist das jedoch eine nicht tragbare Einschränkung. Sollen zur Lokalisierung z.B. die Sensoren eines Smartphones eingesetzt werden, um einen zusätzlichen Hardwareaufwand zu verhindern, ist eine Anbringung am Fuß nicht umsetzbar.

Als Ausblick soll hier noch eine Messung vorgestellt werden (s. Abb. 12), bei der das vorher beschriebene am Fuß befestigte Sensorsystem um eine RFID-Leseeinheit erweitert wurde, mit der auf den Fußboden geklebte RFID Tags bei ausreichender Nähe (etwa 20 cm) registriert werden können. Durch die bekannten Positionen der Tags und eine entsprechende Datenbankabfrage innerhalb des Algorithmus lässt sich die oben beschriebene unbündete Zunahme der Positionsabweichung korrigieren. Die Erkennung eines RFID Tags mit der entsprechenden Positionsinformation wird dazu einfach als zusätzliches Messmodell in den schon beschriebenen Algorithmus eingebunden.

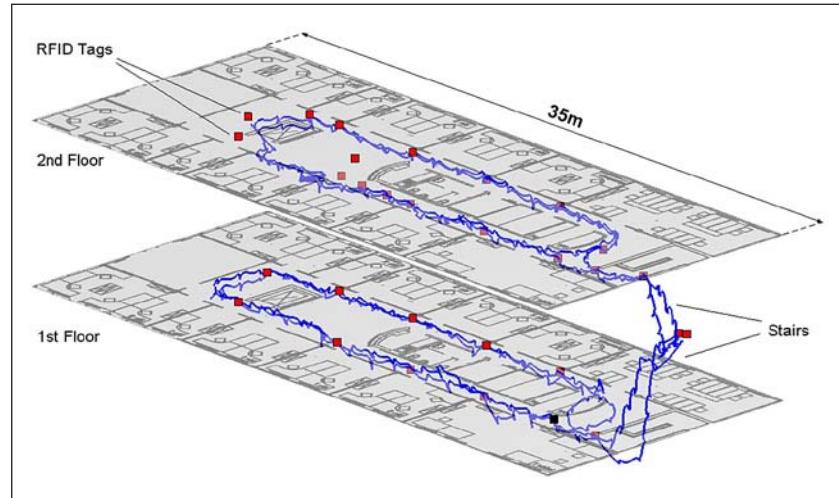


Abb. 12: Geschätzte Trajektorie über zwei Stockwerke, bei der zusätzlich zu den Inertialsensoren RFID Tags mit bekannten Koordinaten zur Stützung der Positionsschätzung eingesetzt werden.

Durchführung zahlreicher Messungen und ihre Arbeiten an der Hard- und Software danken.

## Literatur

- Chehri, A., Fortier, P., Tardif, P. M.: Uwb-based sensor networks for localization in mining environments. *Ad Hoc Networks*, 7(5), 2009, 987–1000.
- Chen, Z.: Bayesian filtering: From Kalman-Filters to particle filters, and beyond. Technical report, Adaptive Syst. Lab., McMaster Univ., Hamilton, ON, Canada, 2003.
- Foxlin, E.: Pedestrian tracking with shoe-mounted inertial sensors. *Computer Graphics and Applications*, IEEE, 25(6), 2005, 38–46.
- Guoping, Z., Rao, S.: Position localization with impulse ultra wide band. In: *Proceedings of Wireless Communications and Applied Computational Electromagnetics*, 2005, 17–22.
- Haykin, S., Ed.: *Kalman-Filtering and Neuronal Networks*. John Wiley & Sons Inc., 2001.
- Hazas, M., Hopper, A.: Broadband ultrasonic location systems for improved indoor positioning. *IEEE Transactions on Mobile Computing*, 5, 2006, 536–547.
- Hightower, J., Borriello, G.: Location systems for ubiquitous computing. *Computer*, 34(8), 2001, 57–66.
- Julier, S., Uhlmann, J., Durrant-Whyte, H.: A new method for the nonlinear transformation of means and covariances in filters and estimators. *Automatic Control, IEEE Transactions on*, 45(3), 2000, 477–482.
- Klann, M.: Tactical navigation support for firefighters: The lifenet ad-hoc sensor-network and wearable system. In: *Mobile Response, Lecture Notes in Computer Science*, Springer Berlin/Heidelberg, 2009, 41–56.
- Klingbeil, L., Romanovas, M., Schneider, P., Traechtler, M., Manoli, Y.: A modular and mobile system for indoor localization. In: *2010 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, 15–17 September 2010, Zuerich, Switzerland, 2010.
- Kuhlmann, H.: Kalman-filtering with coloured measurement noise for deformation analysis. In: *11th FIG International Symposium on Deformation Measurements*, 2003.
- Lee, S.-W., Mase, K.: Activity and location recognition using wearable sensors. *IEEE Pervasive Computing*, 1, 24–32.
- Mazuelas, S., Bahillo, A., Lorenzo, R., Fernandez, P., Lago, F., Garcia, E., Blas, J., Abril, E.: Robust indoor positioning provided by real-time rssi values in unmodified wlan networks. *Selected Topics in Signal Processing, IEEE Journal of*, 3(5), 2002, 821–831.
- Nanotron: Realtime Location Systems (Whitepaper). Nanotron Technologies GmbH, 2007.

## 5 Zusammenfassung

Es wurden verschiedene Methoden der rekursiven Bayesischen Schätzung vorgestellt, wie sie ganz allgemein zur Fusion verschiedener Sensoren in unterschiedlichen Anwendungen eingesetzt werden können. Am Beispiel der Positionsbestimmung von Personen innerhalb von Gebäuden wurden zwei mögliche Sensorkombinationen und die sich daraus ergebene Struktur der Schätzalgorithmen präsentiert. Beide Beispiele verfolgen stark unterschiedliche Ansätze, wie die Sensoren (insbesondere die Inertialsensoren) zur Positionsbestimmung verwendet werden können, sie basieren jedoch auf dem selben algorithmischen Konzept, der Rekursiven Bayesischen Schätzung. Es wurde weiterhin ein modulares Sensorsystem vorgestellt, das mit günstigen Sensorkomponenten ausgestattet ist, und mit dem sich verschiedene Konzepte zur Lokalisierung relativ schnell prototypisch realisieren und evaluieren lassen. Die Ergebnisse zeigen, dass sich trotz teilweise hoher Ungenauigkeiten der Einzelsensoren eine langfristig stabile und je nach Anwendung ausreichende Präzision der Schätzung erreichen lässt, wenn man verschiedene Sensoren, Vorwissen und Bewegungsmodelle geschickt miteinander verbindet.

## Dank

Die Autoren möchten Justinas Trapnauskas von der Vilnius Gediminas Technical University in Litauen und Vadim Goridko von der Hochschule Furtwangen für die

- Neuwinger, B., Witkowski, U., Rückert, U.: Ad-hoc communication and localization system for mobile robots. In: Proceedings of the FIRA RoboWorld Congress 2009 on Advances in Robotics, Berlin, Heidelberg: Springer-Verlag, 2009, 220–229.
- Nister, D., Naroditsky, O., Bergen, J.: Visual odometry. Computer Vision and Pattern Recognition, IEEE Computer Society Conference on, 1, 2004, 652–659.
- Parkka, J., Ermes, M., Korpipaa, P., Mantyjarvi, J., Peltola, J., Korhonen, I.: Activity classification using realistic data from wearable sensors. Information Technology in Biomedicine, IEEE Transactions on, 10(1), 119–128.
- Paul, A., Wan, E.: Rssi-based indoor localization and tracking using sigma-point kalman smoothers. Selected Topics in Signal Processing, IEEE Journal of, 3(5), 2009, 860–873.
- Prusak, A., Melnychuk, O., Roth, H., Schiller, I., Koch, R.: Pose estimation and map building with a time-of-flight-camera for robot navigation. Int. J. Intell. Syst. Technol. Appl., 5(3/4), 2008, 355–364.
- Romanovas, M., Klingbeil, L., Traechtler, M., Manoli, Y.: Efficient orientation estimation algorithm for low cost inertial and magnetic sensor systems. In: 2009 IEEE Workshop on Statistical Signal Processing, Cardiff, Wales, UK: IEEE, 2009.
- Segura, M., Mut, V., Patino, H.: Mobile robot self-localization system using ir-uwb sensor in indoor environments. In: Robotic and Sensors Environments 2009. ROSE 2009, IEEE International Workshop on, 2009, 29–34.
- Takenga, C. M., Kyamakya, K.: Robust positioning system based on fingerprint approach. In: MobiWac '07: Proceedings of the 5th ACM international workshop on Mobility management and wireless access, New York, NY, USA: ACM, 2007, 1–8.
- Thrun, S., Burgard, W., Fox, D.: Probabilistic Robotics (Intelligent Robotics and Autonomous Agents). The MIT Press, 2005.
- Titterton, D., Weston, J.: Strapdown inertial navigation technology. IEE Radar Series, Institution of Electrical Engineers, 2004.
- Varshney, U.: Pervasive healthcare and wireless health monitoring. Mobile Networks and Applications, 12–2, 2007, 113–127.
- Weinberg, H.: Using the ADXL202 in Pedometer and Personal Navigation Applications. Technical report, Analog Devices, 2002.
- Wolf, J., Burgard, W., Burkhardt, H.: Robust vision-based localization by combining an image-retrieval system with monte carlo localization. IEEE Transactions on Robotics, 21(2), 2005, 208–216.

**Anschrift der Autoren**

Dr. rer. nat. Lasse Klingbeil  
Rheinische Friedrich-Wilhelms-Universität Bonn  
Institut für Geodäsie und Geoinformation (IGG)  
Nussallee 17, 53115 Bonn  
klingbeil@igg.uni-bonn.de

M. Sc. Michailas Romanovas  
Hahn-Schickard-Gesellschaft für angew. Forschung e.V.  
Institut für Mikro- und Informationstechnik (HSG-IMIT)  
Wilhelm-Schickard-Straße 10, 78052 Villingen-Schwenningen  
michailas.romanovas@hsg-imit.de