

Modellbasierte Quellenverfolgung in räumlich ausgedehnten Phänomenen mittels Sensoreinsatzplanung

Model-based Tracking of Movable Sources in Spatially Distributed Phenomena
Using Sensor Management

Achim Kuwertz, Karlsruher Institut für Technologie (KIT),
Marco F. Huber, Felix Sawo, Fraunhofer-Institut für Optronik, Systemtechnik
und Bildauswertung IOSB, Karlsruhe,
Uwe D. Hanebeck, Karlsruher Institut für Technologie (KIT)

Zusammenfassung Bewegte Quellen können durch Emission räumlich ausgedehnte Phänomene wie beispielsweise Schadstoff- oder Temperaturverteilungen erzeugen. Zur Lokalisierung von Quellen mit unbekannter Position stehen in vielen Aufgabenstellungen Informationen nur indirekt durch die verteilte Vermessung des induzierten Phänomens zur Verfügung – etwa unter Verwendung stationärer oder mobiler Sensoren. Dieser Beitrag stellt modellbasierte Verfahren für eine echtzeitfähige Lokalisierung und Verfolgung von bewegten Quellen vor. Zur gezielten Maximierung des Informationsgehalts der Messungen wird dabei eine vorausschauende Sensoreinsatzplanung genutzt, welche eine hohe Lokalisierungsgüte bei geringem Aufwand ermöglicht.

▶▶▶ Summary Space-time continuous phenomena such as pollution loads or temperature distributions often originate from unknown and possibly movable sources. In many real-world scenarios, however, information about the location of such sources can only be gained indirectly by monitoring the induced physical phenomena using distributed sensing systems, e.g., stationary or mobile sensors. In this article, a model-based approach for real-time source localization and target tracking is introduced. To maximize specific information gained from the measurements, this approach strongly relies on a non-myopic sensor management methodology, which allows for tracking moving sources in an efficient and accurate manner.

Schlagwörter Sensoreinsatzplanung, Quellenlokalisierung, Tracking, nichtlineare Zustandsschätzung, Kontrolle mobiler Sensoren
▶▶▶ Keywords Sensor scheduling, source localization, target tracking, non-linear state estimation, mobile sensor control

1 Einleitung

In der Natur und in der vom Menschen geschaffenen Umgebung treten häufig *räumlich ausgedehnte Phänomene* auf. Beispiele solcher Phänomene sind Verteilungen

von Schadstoffen in Luft oder Wasser, wie etwa aus Lecks austretende Gase oder Ölteppiche in Meeren sowie Temperaturverteilungen über ausgedehnten Gebieten. Diese Verteilungen von physikalischen Quantitäten




Bild 1 Lokalisierung und Verfolgung von Quellen ausgedehnter Phänomene durch stationäre und mobile Sensoren.

sind dabei alle durch einen kontinuierlichen räumlichen Verlauf über ihrem Ausbreitungsgebiet sowie durch eine kontinuierliche zeitliche Veränderung dieses Verlaufs charakterisiert.

Die *technische Erfassung und Vermessung* von räumlich ausgedehnten Phänomenen ist eine sinnvolle und gewinnbringende Aufgabe, da sie es beispielsweise ermöglicht, das Vorhandensein und die Ausbreitung von Schadstoffen zu detektieren und zu überwachen. Somit können Belastungen für Mensch und Umwelt durch derartige Gefahrenstoffe erkannt und abgewendet werden. Als weiterer Nutzen dieser Erfassung können zusätzliche Erkenntnisse über räumlich ausgedehnte Phänomene gewonnen werden, z. B. in Form von verbesserten Ausbreitungsmodellen.

Um ausgedehnte Phänomene durch eine Vermessung ausreichend erfassen zu können, sind Messungen an verschiedenen Raumpositionen und zu verschiedenen Zeitpunkten notwendig. Ein *verteilt Messsystem* wie beispielsweise ein stationäres Sensornetz [1] oder eine Gruppe von mobilen Robotern ist daher ideal für die Erfassung derartiger Phänomene geeignet. Allerdings liefern diese Messsysteme nur punktuelle Messungen. Zur Darstellung eines kontinuierlichen Phänomens ist daher eine Rekonstruktion erforderlich. Abschnitt 2 stellt zu dieser Problematik die *modellbasierte Rekonstruktion* vor.

Quellenlokalisierung. Ein besonders interessantes und zugleich herausforderndes Gebiet der Erfassung von physikalischen Verteilungen ist die *Lokalisierung der Quelle* [2] einer räumlich ausgedehnten Verunreinigung. Die besondere Schwierigkeit dieser Aufgabe liegt dabei in der Tatsache, dass zur Lokalisierung einer Quelle keine *direkten* Messverfahren wie Abstands- oder Winkelmessungen zur Verfügung stehen. Informationen über die Quelle können nur *indirekt* durch eine Erfassung des von ihr induzierten räumlich ausgedehnten Phänomens gewonnen werden. Für bewegte Quellen muss eine Lokalisierung weiterhin schritthaltend, d. h. mit fortlaufender Erfassung des Phänomens, erfolgen. Die modellbasierte Lokalisierung einer bewegten Quelle durch ein stationäres Sensornetz, wie in Bild 1a illustriert, wird in Abschnitt 3 vorgestellt. Ähnliche Aufgabenstellungen werden beispielsweise in [3; 4] behandelt.

Verfolgung. Eine Erweiterung der Lokalisierung durch ein stationäres Sensornetz stellt die *Verfolgung einer Quelle* durch mobile Sensoren dar, in welcher die Sensoren schritthaltend an möglichst optimalen Messpositionen platziert werden. Dabei ist ein *Szenario* wie in Bild 1b vorstellbar: Auf einem begrenzten Gebiet, beispielsweise in einer Lagerstätte für Chemikalien, wurde das Austreten von flüchtigen Gefahrenstoffen bemerkt. Um eine Gefährdung der menschlichen Gesundheit zu vermeiden, werden autonome mobile Roboter eingesetzt. Ein Roboter verfügt dabei über Sensoren, mit welchen die Konzentration der Gefahrenstoffe jeweils an der aktuellen Roboterposition gemessen werden kann. Die Aufgabe der Roboter ist es nun, durch Messungen an verschiedenen Raumpositionen die Quelle der Kontamination in möglichst kurzer Zeit zu identifizieren, zu lokalisieren und zu verfolgen.

Um eine derartige Aufgabe erfolgreich lösen zu können, müssen die Roboter mit Verfahren zur Pfadplanung ausgestattet sein [5; 6]. Ein modellbasiertes Planungsverfahren zur Quellenverfolgung wird daher in Abschnitt 4 vorgestellt. Abschnitt 5 fasst abschließend die Vorteile dieses Planungsverfahrens zusammen.

Der vorliegende Beitrag basiert als aktualisierte Fassung auf [7].

2 Modellbasierte Rekonstruktion

Räumlich ausgedehnte Phänomene stellen eine kontinuierliche Verteilung von physikalischen Größen im Raum dar, welche sich kontinuierlich mit der Zeit ändern. Genauer gesagt lassen sich diese Phänomene mathematisch als eine Funktion $p(\underline{z}, t)$ beschreiben, wobei $\underline{z} \in \mathbb{R}^3$ oder $\underline{z} \in \mathbb{R}^2$ eine Raumkoordinate und $t \in \mathbb{R}_+$ einen Zeitpunkt bezeichnet.

Als Voraussetzung für eine erfolgreiche Quellenlokalisierung ist eine ausreichende Erfassung der induzierten Verteilung notwendig. Ein verteiltes Messsystem liefert dabei punktuelle Messungen wie beispielsweise Konzentrationswerte und erreicht daher nur eine *diskrete Abtastung* eines kontinuierlichen Phänomens an einzelnen Raum- und Zeitpunkten. Über Werte an Punkten in Raum und Zeit, für welche keine Messungen vorliegen, lassen sich zunächst keine Aussagen treffen.

Um hohe räumliche und zeitliche Abstraten zu vermeiden, können Interpolationstechniken zur Gewinnung




Bild 2 Rekonstruktion (hell) eines 1D-Temperaturverlaufs (dunkel, gestrichelt) aus Messungen von Sensoren (Punkte) mit Unsicherheit als 3σ -Grenze (Strichpunktlinie) zu verschiedenen Zeitpunkten t_k .

von Phänomenwerten für Nicht-Messpunkte angewendet werden. Dieser Beitrag wendet dazu die Methode der *modellbasierten Rekonstruktion* [8;9] an, welche neben einer Interpolation auch die Synchronisation von zu verschiedenen Zeitpunkten erfassten Messwerten erlaubt. Als Grundlage dieser Berechnungen dient dabei ein mathematisches Modell des betrachteten Phänomens.

Viele räumlich ausgedehnte Phänomene lassen sich mathematisch durch partielle Differenzialgleichungen (PDE) charakterisieren. Dieser Beitrag konzentriert sich auf die Erfassung von linearen Phänomenen in der Ebene, wie beispielsweise *Diffusions-Advektions- oder Wärmeleitungsphänomene*. Diese Phänomene können mit $\nabla^j p := \frac{\partial^j p}{\partial z^j} + \frac{\partial^j p}{\partial t^j}$ als lineare PDE der Form

$$\mathbb{L}\left(p(z, t), s(z, t), \frac{\partial p}{\partial t}, \dots, \frac{\partial^j p}{\partial t^j}, \nabla p, \dots, \nabla^j p\right) = 0$$

beschrieben werden, wobei $\mathbb{L}(\cdot)$ einen linearen Operator und $s(z, t)$ die von der Phänomenquelle pro Raum- und Zeitpunkt eingebrachte Anregung bezeichnet.

Zur Lösung von linearen PDEs werden in der modellbasierten Rekonstruktion Diskretisierungsverfahren genutzt. Dieser Beitrag wendet zur Raumdiskretisierung die *Finite-Elemente-Methode* [10] und zur Zeitdiskretisierung das Crank-Nicolson-Verfahren [11] an.

In der Finite-Elemente-Methode wird die verteilt-parametrische Beschreibung eines Phänomens in Form einer PDE durch Diskretisierung des Raums in ein konzentriert-parametrisches System in Zustandsraumform überführt. Dazu wird die das Phänomen beschreibende Lösungsfunktion $p(z, t)$ über die Summe

$$p(z, t) \approx \sum_{i=0}^N \Phi_i(z) \cdot x_i(t) \tag{1}$$

als endliche Reihenentwicklung approximiert. In dieser Summe werden die Orts- und Zeitabhängigkeit getrennt durch die ortsabhängigen Basisfunktionen $\Phi_i(z)$ und die zeitabhängigen Skalierungsfaktoren $x_i(t)$ dargestellt.

Als Ergebnis dieser Darstellung lässt sich die ortsdiskretisierte Lösungsfunktion zu jedem Zeitpunkt t durch den Vektor der Skalierungsfaktoren $\underline{x}(t) := [x_0(t), x_1(t), \dots, x_N(t)]^T$ beschreiben. Durch Anwendung der Zeitdiskretisierung kann die PDE dann in ein zeitdiskretes System aus gewöhnlichen Differenzial-

gleichungen in Zustandsraumform gemäß

$$\underline{x}_{k+1} = \mathbf{A} \cdot \underline{x}_k + \mathbf{B} \cdot \underline{s}_k \tag{2}$$

überführt werden. Die Systemmatrix \mathbf{A} charakterisiert dabei das System, die Eingangsmatrix \mathbf{B} dient der Einbringung der diskretisierten Anregung \underline{s}_k . Insgesamt lassen sich mit Hilfe dieser mathematischen Modellierung die Werte des Phänomens an einem beliebigen Raumpunkt z_n zum Zeitpunkt t_k aus dem Zustandsvektor \underline{x}_k nach Gleichung (1) gemäß $p(z_n, t_k) = \underline{\Phi}^T(z_n) \cdot \underline{x}_k$ interpolieren, wobei $\underline{\Phi} := [\Phi_0, \Phi_1, \dots, \Phi_N]^T$ gilt.

Für die *Rekonstruktion* eines räumlich ausgedehnten Phänomens muss somit insgesamt nur sein Zustandsvektor \underline{x}_k aus den erfassten Messwerten bestimmt werden. In der modellbasierten Rekonstruktion wird dieses Problem durch *stochastische Schätzverfahren* wie das bekannte Kalman-Filter gelöst. Dazu werden die Gleichungen (1) und (2) durch Interpretation des Zustandsvektors als Zufallsvektor in eine stochastische Form überführt und als *Mess- und Systemmodell* genutzt.

Bild 2 zeigt beispielhaft die Ergebnisse der modellbasierten Rekonstruktion eines eindimensionalen Temperaturverlaufs zu verschiedenen Zeitpunkten t_k . Dabei wird sowohl die Annäherung des rekonstruierten Verlaufs (hell) an die vorgegebene Temperatur (dunkel gestrichelt) als auch die Reduktion der Schätzunsicherheit (3σ -Grenze, strichpunktiert) deutlich.

3 Lokalisierung als Schätzproblem

Im vorigen Abschnitt wurde eine Phänomenrekonstruktion auf Basis eines linearen Systemmodells und einer bekannten Anregungsfunktion durchgeführt. Um eine *Lokalisierung von Phänomenquellen* zu ermöglichen, ist das Systemmodell auf unbekannte Anregungsfunktionen zu erweitern. Dazu lassen sich parametrische Anregungsfunktionen definieren, welche die erzeugte Anregung in Abhängigkeit der Quellenposition \underline{z}_k^Q darstellen.

Zur Modellierung von lokalen Quellen mit räumlich begrenzter Anregung werden in diesem Beitrag zwei verschiedene Funktionen genutzt. Punktförmige Quellen werden dabei als Dirac-Delta-Impuls dargestellt. Lokal ausgedehnte Quellen werden dagegen als Gaußfunktionen modelliert. Die Diskretisierung dieser lokalen parametrischen Anregungsfunktionen in Raum und Zeit

liefert dann den Anregungsvektor $\underline{s}_k(\underline{z}_k^Q)$, welcher sich als eine *nichtlineare Funktion* der Quellenposition \underline{z}_k^Q ergibt.

In der Quellenlokalisierung ist die Position einer Quelle zunächst unbekannt. Für die Zustandsschätzung in der modellbasierten Rekonstruktion bedeutet dies, dass nun ein unbekannter Parameter im Systemmodell auftritt, wodurch die Rekonstruktion zugleich zum *Parameterschätzproblem* wird. Simultan zur Rekonstruktion der Phänomenverteilung muss dabei die Quellenposition geschätzt werden, und zwar wie bisher ausschließlich auf Basis der gemessenen Phänomenwerte.

Zustandserweiterung. Das Parameterschätzproblem wird in diesem Beitrag durch eine Zustandserweiterung gelöst, welche die Quellenposition als unbekannt Variable in den erweiterten Systemzustand $\underline{\hat{x}}_k := [\underline{x}_k^T, (\underline{z}_k^Q)^T]^T$ integriert. Diese Anpassung erfolgt analog auch für das Systemmodell. Aufgrund der nichtlinearen Abhängigkeit der Anregungsfunktion vom erweiterten Systemzustand ergibt sich dabei ein *nichtlineares Systemmodell*. Dies erschwert die Zustandsschätzung, da in stochastischen Schätzverfahren der Systemzustand $\underline{\hat{x}}_k$ als Zufallsvektor durch eine Wahrscheinlichkeitsdichte dargestellt wird, welche in jedem Verarbeitungsschritt durch Prädiktion zeitlich mit anfallenden Messwerten synchronisiert werden muss. Für nichtlineare Systemmodelle kann dabei die aus einer Prädiktion resultierende Zustandsdichte im Allgemeinen nicht geschlossen berechnet werden.

Gaußfilter. Eine mögliche Lösung dieser Problematik besteht in der approximativen Berechnung der prädierten Zustandsdichte. In diesem Beitrag wird dazu das *Gaußfilter* [12; 13] als eine nichtlineare Erweiterung des Kalman-Filters genutzt. Das prinzipielle Vorgehen dieses Filters ist in Bild 3 illustriert. Im Gaußfilter wird eine gegebene Zustandsdichte nicht direkt verarbeitet, sondern zunächst durch sogenannte Sigmapunkte repräsentiert. Diese Sigmapunkte werden anschließend anstelle der eigentlichen Dichte durch das nichtlineare Systemmodell propagiert. Als Ergebnis kann dann die prädierte Zustandsdichte approximativ aus den transformierten Sigmapunkten berechnet werden. Die Vorteile des Gauß-




Bild 3 Prinzip der Dichteapproximation im Gaußfilter.

filters liegen dabei in einer effizienten Berechnung der Sigmapunkte und der Möglichkeit, die nichtlinear zu verarbeitenden Zustandsdimensionen durch Dekomposition reduzieren zu können. Die in [12] beschriebene Erweiterung auf ein Gaußmischdichte-Filter zur Behandlung beliebiger Dichtefunktionen, d.h. die Anwendung des Gaußfilters auf mehrere gewichtete Gaußdichten, reduziert zudem den Lokalisierungsfehler.

Zur Demonstration der entwickelten Verfahren wurde eine simulierte Quellenverfolgung durchgeführt. Wie in Bild 4a gezeigt, bewegt sich dabei eine Quelle in einem Gebiet, welches von zwei stationären Sensornetzen mit jeweils 9 bzw. 25 gleichzeitig aktiven Sensorknoten überwacht wird. Die in Bild 4b dargestellten Ergebnisse der Quellenlokalisierung über 100 Zeitschritte zeigen, dass eine höhere Anzahl an Sensoren zwar zu einer schnelleren Konvergenz führt, langfristig aber beide Sensornetze eine ähnliche Lokalisierungsgüte erreichen.

4 Verfolgung mittels Planung

Aufbauend auf der zuvor vorgestellten schritthaltenden Lokalisierung von Quellen lässt sich nun das eingangs beschriebene Szenario der *Verfolgung* einer bewegten Quelle durch mobile Sensoren realisieren.

Mobile Sensoren bieten gegenüber einem stationären Sensornetz den Vorteil, Messungen an verschiedenen, zur Laufzeit auswählbaren Raumpositionen durchführen zu können. Aufgrund dieser Mobilität lässt sich die Anzahl der zur Messung genutzten Sensoren reduzieren. Eine unüberlegte Reduktion führt dabei allerdings zu einem Abfall der Lokalisierungsgenauigkeit, wie bereits

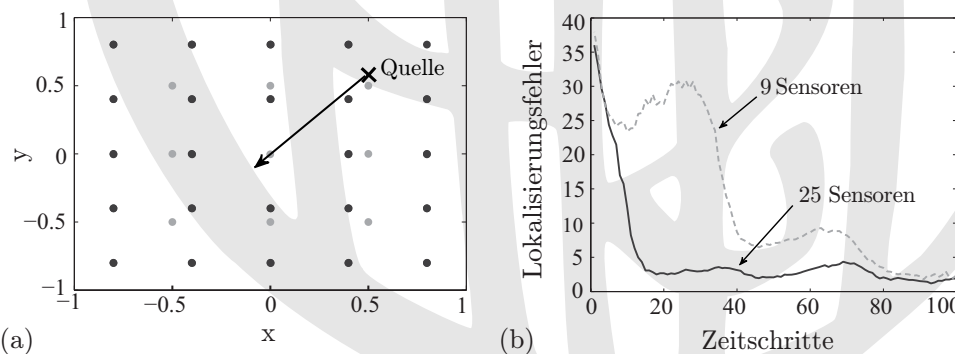


Bild 4 (a) Stationäres Sensornetz mit 9 (hell) bzw. 25 (dunkel) Sensorknoten; bewegte Quelle. (b) Prozentualer Lokalisierungsfehler der modellbasierten schritthaltenden Quellenlokalisierung für Messungen mit 9 bzw. 25 Sensorknoten.

an den Ergebnissen in Bild 4b erkennbar. Um trotz einer reduzierten Sensoranzahl eine hohe Lokalisierungsgenauigkeit zu erreichen, ist daher eine sorgfältige Auswahl der Messpositionen notwendig. Dieser Tatsache trägt der vorliegende Beitrag durch die Nutzung von Verfahren zur *Sensoreinsatzplanung* Rechnung.

Eine *Sensoreinsatzplanung* hat dabei die Maximierung der aus Messungen über ein gegebenes System gewonnenen Information unter Beachtung von existierenden Nebenbedingungen zum Ziel. Im Falle einer Quellenverfolgung bedeutet dies, die Genauigkeit der Quellenlokalisierung unter Nutzung einer vorgegebenen Anzahl von mobilen Sensoren zu maximieren. Prinzipiell muss dazu für einen Sensor in jedem Zeitschritt aus einer (endlichen) Menge der möglichen Messpositionen diejenige Position \underline{u}_k^S ausgewählt werden, welche zur höchsten Lokalisierungsgenauigkeit führt.

Wird eine Quellenverfolgung über einen längeren Zeitraum durchgeführt, so muss die Einsatzplanung pro Sensor eine ganze Sequenz von optimalen Messpositionen bestimmen. Um dabei verschiedene Messpositionen quantitativ bezüglich ihres Nutzens vergleichen zu können, ist die Definition eines Gütemaßes erforderlich, welches die resultierende Lokalisierungsgenauigkeit möglichst gut vorhersagt. In diesem Beitrag wird dazu ein kovarianzbasiertes Gütemaß genutzt, das zur Vorhersage der Lokalisierungsgenauigkeit die Schätzunsicherheit der Quellenposition \underline{z}_k^Q in Form der entsprechenden Kovarianzen nutzt, z. B. als die Summe

$$G(\underline{u}_k^S) := \text{Cov}(\underline{z}_{x,k}^Q) + \text{Cov}(\underline{z}_{y,k}^Q).$$

Nachfolgend wird die Einsatzplanung in der Quellenverfolgung durch einen mobilen Sensor vorgestellt. Zur Planung über einen Beobachtungszeitraum von L Zeitschritten wird dabei die *quasi-lineare Einsatzplanung* [12] genutzt. Dieses Verfahren stellt eine Erweiterung der linearen Einsatzplanung dar, welche sich im Fall von Systemen mit linearen System- und Messmodellen sowie gaußverteilten Unsicherheiten anwenden lässt.

Die *lineare Einsatzplanung* besitzt dabei den Vorteil, dass sich für kovarianzbasierte Gütemaße die Entwicklung der Güte über den Beobachtungszeitraum unabhängig von den tatsächlichen Messwerten und somit bereits im Voraus berechnen lässt [14]. Zur Bestimmung einer optimalen Sequenz von Messpositionen muss daher nur die Güte aller Messsequenzen der Länge L miteinander verglichen werden. Dieser Vergleich kann dabei als eine *Suche im Baum* aller möglichen Messsequenzen realisiert werden.

Um diese Suche möglichst effizient zu gestalten, lassen sich Pruning-Techniken nutzen [12]. Weiterhin werden in diesem Beitrag Techniken der *modell-prädiktiven Regelung* [15] genutzt, welche eine optimale Messsequenz nicht für den gesamten Beobachtungszeitraum, sondern nur über einen verkürzten Planungshorizont $P < L$ berechnen. Dieses Vorgehen stellt dabei einen sinnvollen




Bild 5 Berechnung einer Linearisierungstrajektorie in der quasi-linearen Einsatzplanung, aus [12].

Kompromiss aus Suchaufwand und Planungsgüte dar und ermöglicht eine Planung in Echtzeit.

Für *nichtlineare Systeme* gestaltet sich eine Sensoreinsatzplanung jedoch deutlich komplexer. Dabei lässt sich für derartige Systeme vor allem die Entwicklung der Güte nicht mehr unabhängig von den tatsächlichen Messwerten berechnen. Eine Möglichkeit, auch für nichtlineare Systeme die Vorteile einer linearen Einsatzplanung nutzen zu können, besteht in der Approximation des Systems durch lineare Modelle. Dieser Ansatz wird in der *quasi-linearen Sensoreinsatzplanung* verfolgt. Als Grundidee wird dabei die als statistische Linearisierung bekannte Approximationstechnik des Gaußfilters für eine prädiktive Einsatzplanung genutzt, welche nur auf den bereits erfassten (tatsächlichen) Messwerten basiert. Dies liefert eine effiziente Approximation des nichtlinearen Planungsproblems, welche dann durch lineare Verfahren behandelt werden kann. Die Zustandsschätzung erfolgt jedoch weiterhin auf nichtlineare Weise.

Das prinzipielle Vorgehen der *prädiktiven statistischen Linearisierung* ist in Bild 5 illustriert. Der prädizierte Systemzustand \underline{x}_{k+j} wird dabei für alle j im Planungshorizont $\{1, 2, \dots, P\}$ über eine sogenannte Linearisierungstrajektorie von Sigma-punkten berechnet. Ausgehend vom aktuellen Systemzustand \underline{x}_k wird dessen Dichte (1) durch eine Gaußdichte approximiert (2) und anschließend durch eine Menge von Sigma-punkten $\underline{\sigma}_{i,k}$ dargestellt (3).

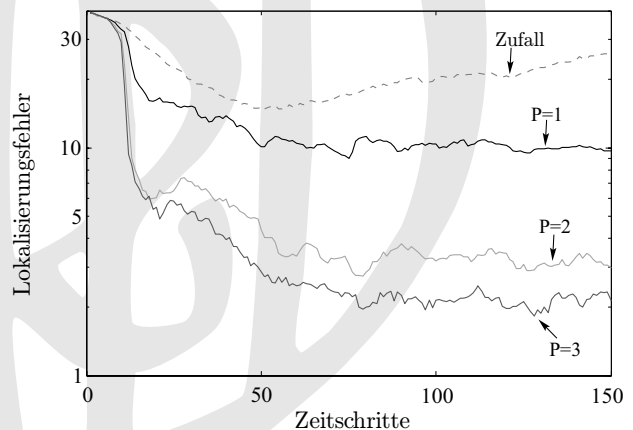


Bild 6 Prozentualer Lokalisierungsfehler der modellbasierten Quellenverfolgung mit einem mobilen Sensor für vier Planungshorizonte.

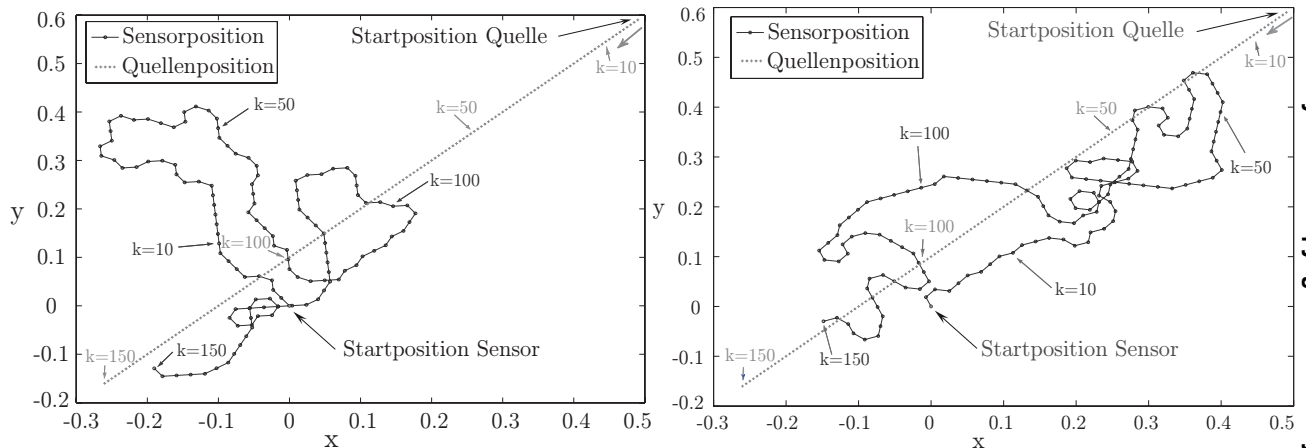


Bild 7 Bewegungstrajektorie der Quelle (hell) und des mobilen Sensors (dunkel) in der modellbasierten Quellenverfolgung für die Planungshorizonte $P = 1$ (links) und $P = 3$ (rechts).

Die gewünschte Linearisierungstrajektorie ergibt sich dann, indem für alle j die berechneten Sigmapunkte rekursiv durch das nichtlineare Systemmodell propagiert werden (4–5). Basierend auf der Sigmapunkttrajektorie kann anschließend das nichtlineare System- und Messmodell durch *statistische lineare Regression* für jeden Planungszeitschritt einzeln linearisiert werden. Das lineare Systemmodell im Zeitschritt t_{k+j} wird dabei beispielsweise durch Bestimmung einer linearen Abbildung zwischen den beiden durch die Sigmapunktfolgen $\{\underline{\sigma}_{i,k+j-1}\}$ und $\{\underline{\sigma}_{i,k+j}\}$ repräsentierten Zufallsvektoren approximiert.

Abschließend werden die *Ergebnisse einer simulierten Quellenverfolgung* mit einem einzelnen mobilen Sensor präsentiert. Dazu wird das bereits in Abschnitt 3 beschriebene Szenario wiederverwendet, hier über 150 Zeitschritte. In Bild 6 ist die prozentuale Lokalisierungsgenauigkeit, bezogen auf die Größe des überwachten Gebiets, für unterschiedliche Planungshorizonte der Länge eins bis drei und eine zufällige Sensorauswahl dargestellt. Längere Horizonte führen hierbei zu einer höheren Genauigkeit. Insgesamt erreicht ein einzelner mobiler Sensor in diesem Szenario ähnlich gute Ergebnisse wie ein stationäres Sensornetz mit 25 Knoten. In Bild 7 sind weiterhin zwei exemplarische Bewegungstrajektorien des mobilen Sensors und der Quelle für verschiedene Planungshorizonte P abgebildet. Dabei ist zu erkennen, wie der Sensor anfänglich das zu überwachende Gebiet für $P = 1$ großräumig abfährt, während er für $P = 3$ gezielt in Richtung der Quelle fährt. Mit ansteigender Lokalisierungsgüte folgt der Sensor dann der Quelle in einer mäanderförmigen Bewegung zur gleichmäßigen Reduktion der Schätzunsicherheit.

5 Zusammenfassung

Die in diesem Beitrag vorgestellten Verfahren zur Quellenlokalisierung und -verfolgung zeichnen sich durch folgende Besonderheiten aus:

- Der *modellbasierte Ansatz* mit *numerischer Lösung* ermöglicht ein rekursives Verarbeitungsschema und geringe Messraten.
- *Stochastische Filterverfahren* erlauben die fortlaufende *Quantifizierung der Lokalisierungsgenauigkeit* in Form der Schätzunsicherheit.
- Das Gaußmischfilter ermöglicht die effiziente rekursive *Lokalisierung bewegter Quellen unter Echtzeitbedingungen*.
- Effiziente *Einsatzplanungsverfahren* erlauben die schritthaltende *Quellenverfolgung* durch *mobile Sensoren* sowie die genaue und *ressourcenschonende Lokalisierung* durch wenige (aktive) Sensoren.

Literatur

- [1] I. F. Akyildiz, S. Weilian, Y. Sankarasubramaniam und E. Cayirci: A Survey on Sensor Networks, *IEEE Communications Magazine*, 40, 102–114 (2002).
- [2] M. E. Alpay und M. H. Shor: Model-based Solution Techniques for the Source Localization Problem, *IEEE Transactions on Control Systems Technology*, 8, 895–904 (2000).
- [3] J. Matthes: *Eine neue Methode zur Quellenlokalisierung auf der Basis räumlich verteilter, punktwiser Konzentrationsmessungen*. Dissertation, Universität Karlsruhe (TH), 2004.
- [4] M. A. Demetriou: Power management of sensor networks for detection of a moving source in 2-D spatial domains, in *Proceedings of the 2006 American Control Conference*, Minneapolis, 2006, S. 1144–1149.
- [5] M. Patan und D. Uciński: Optimal scheduling of mobile sensor networks for detection and localization of stationary contamination sources, in *Proceedings of the 11th International Conference on Information Fusion (Fusion 2008)*, Köln, 2008, S. 366–372.
- [6] B. Porat und A. Nehorai: Localizing Vapor-Emitting Sources by Moving Sensors, in *Conference Record of the Twenty-Eighth Asilomar Conference on Signals, Systems and Computers*, 2, Oct. 1994, S. 765–769.
- [7] A. Kuwertz, M. F. Huber, F. Sawo und U. D. Hanebeck: Sensoreinsatzplanung zur Verfolgung von Quellen räumlich ausgedehnter Phänomene, in *Verteilte Messsysteme*. KIT Scientific Publishing, Feb. 2010, S. 179–191.
- [8] F. Sawo: *Nonlinear State and Parameter Estimation of Spatially Distributed Systems*. Dissertation, Universität Karlsruhe (TH), 2009.

- [9] D. Brunn, F. Sawo und U.D. Hanebeck: Informationsfusion für verteilte Systeme, in *Informationsfusion in der Mess- und Sensortechnik*. Universitätsverlag Karlsruhe, Sep. 2006, S. 75–90.
- [10] A. J. Baker: *Finite Element Computational Fluid Mechanics*. Taylor and Francis, 1983.
- [11] J. Crank und P. Nicolson: A practical method for numerical evaluation of solutions of partial differential equations of the heat-conduction type, *Advances in Computational Mathematics*, 6(1), 207–226 (1996).
- [12] M. F. Huber: *Probabilistic Framework for Sensor Management*. Dissertation, Universität Karlsruhe (TH), 2009.
- [13] M. F. Huber und U. D. Hanebeck: Gaussian Filter based on Deterministic Sampling for High Quality Nonlinear Estimation, in *Proceedings of the 17th IFAC World Congress*, 17, Seoul, 2008.
- [14] L. Meier, III, J. Peschon und R. M. Dressler: Optimal control of measurement subsystems, *IEEE Transactions on Automatic Control*, 12(5), 528–536 (1967).
- [15] M. Morari und J. H. Lee: Model Predictive Control: Past, Present and Future, *Computers and Chemical Engineering*, 1997.

Manuskripteingang: 31. Mai 2010, zur Veröffentlichung angenommen: 31. August 2010

Dipl.-Inform. Achim Kuwertz ist wissenschaftlicher Mitarbeiter am Karlsruher Institut für Technologie (KIT) und arbeitet in enger Kooperation mit dem Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung IOSB. Sein Hauptarbeitsgebiet ist die Informationsfusion.

Adresse: Lehrstuhl für Interaktive Echtzeitsysteme (IES), Institut für Anthropomatik, Karlsruher Institut für Technologie (KIT), Adenau-

erring 4, 76131 Karlsruhe, Deutschland, Tel.: +49-721-6091-231, Fax: +49-721-608-5926, E-Mail: achim.kuwertz@kit.edu

Dr.-Ing. Marco F. Huber ist Leiter der Forschungsgruppe „Variable Bildgewinnung- und -verarbeitung“ (VBV) am Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung IOSB. Seine Hauptarbeitsgebiete sind: Sensoreinsatzplanung, Informationsfusion, maschinelles Lernen.

Adresse: Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung IOSB, Fraunhoferstraße 1, 76131 Karlsruhe, Deutschland, Tel.: +49-721-608-5912, Fax: +49-721-608-5926, E-Mail: marco.huber@ieee.org

Dr.-Ing. Felix Sawo ist wissenschaftlicher Mitarbeiter der Abteilung „Mess-, Regelungs- und Diagnosesysteme“ (MRD) am Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung IOSB. Seine Hauptarbeitsgebiete sind: Modellierung und Diagnose technischer Prozesse, Informationsfusion, maschinelles Lernen.

Adresse: Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung IOSB, Fraunhoferstraße 1, 76131 Karlsruhe, Deutschland, Tel.: +49-721-6091-436, Fax: +49-721-6091-413, E-Mail: felix.sawo@iosb.fraunhofer.de

Prof. Dr.-Ing. Uwe D. Hanebeck ist Leiter des Lehrstuhls für „Intelligente Sensor-Aktor-Systeme“ (ISAS) am Institut für Anthropomatik des Karlsruher Instituts für Technologie (KIT). Seine Hauptarbeitsgebiete sind: Nichtlineare System- und Schätztheorie, Sensor-Aktor-Netzwerke, Telepräsenzsysteme, Robotik, Medizintechnik, persönliche assistive Systeme.

Adresse: Lehrstuhl für Intelligente Sensor-Aktor-Systeme (ISAS), Institut für Anthropomatik, Karlsruher Institut für Technologie (KIT), Adenauerring 2, 76131 Karlsruhe, Deutschland, Tel.: +49-721-608-3909, Fax: +49-721-608-5340, E-Mail: uwe.hanebeck@ieee.org