

Sensoreinsatzplanung zur Verfolgung von Quellen räumlich ausgedehnter Phänomene

Achim Kuwertz¹, Marco F. Huber²,
Felix Sawo² und Uwe D. Hanebeck¹

¹ Institut für Anthropomatik, Karlsruher Institut für Technologie (KIT),

E-Mail: kuwertz@ira.uka.de, uwe.hanebeck@ieee.org

² Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung (IOSB),

E-Mail: marco.huber@ieee.org, felix.sawo@iosb.fraunhofer.de

Zusammenfassung Räumlich ausgedehnte Phänomene wie Schadstoffverteilungen in Gewässern oder Temperaturverteilungen in Räumen werden vielfach durch unbekannte, gegebenenfalls sich bewegende Quellen erzeugt. Allerdings stehen in vielen praktisch relevanten Aufgabenstellungen Informationen zur Lokalisierung einer derartigen Quelle nur indirekt durch eine Vermessung des induzierten Phänomens zur Verfügung, welche den Einsatz eines verteilten Messsystems erfordert. Die Messungen können dabei beispielsweise von einem stationären Sensornetz oder von mobilen Sensoren stammen. In diesem Beitrag werden modellbasierte Verfahren zur echtzeitfähigen Lokalisierung und schritthaltenden Verfolgung von Quellen vorgestellt, welche gezielt räumlich und zeitlich verteilte Messungen einsetzen. Um den Informationsgewinn und somit den Nutzen verteilter Messungen zu maximieren, spielt bei diesen Verfahren neben einer mathematischen Modellierung auch eine vorausschauende Sensoreinsatzplanung eine zentrale Rolle. Das in diesem Beitrag vorgeschlagene Planungsverfahren ermöglicht dabei die effiziente und ressourcenschonende Verfolgung beweglicher Quellen bei gleichzeitig hoher Lokalisierungsgenauigkeit.

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




Abbildung 15.1: Lokalisierung und Verfolgung von Quellen räumlich ausgedehnter Phänomene durch stationäre und mobile Sensoren.

Lecks austretende Gase oder Ölteppiche in Meeren sowie Temperaturverteilungen über räumlich ausgedehnten Gebieten oder in geschlossenen Räumen. Diese Verteilungen von physikalischen Quantitäten 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 zusätzlicher Nutzen dieser Erfassung können weiterhin die Erkenntnisse über räumlich ausgedehnte Phänomene vergrößert werden, z. B. in Form von verbesserten Ausbreitungsmodellen.

Um ein räumlich ausgedehntes Phänomen 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 Ver-

unreinigung. 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 Abb. 15.1(a) 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 Abb. 15.1(b) 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 gegenüber anderen Ansätzen zusammen.

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 in einzelnen Raumpunkten und zu verschiedenen 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 Abtastraten zu vermeiden, können Interpolationstechniken zur Gewinnung von Phänomenwerten für Nicht-Messpunkte angewendet werden. In diesem Beitrag wird dazu die Methode der *modellbasierten Rekonstruktion* [7, 8] genutzt, welche neben einer Interpolation auch die Synchronisation von zu verschiedenen Zeitpunkten erfassten Messwerten erlaubt. Als Grundlage dieser Berechnungen dient dabei ein mathematisches Modell des zu erfassenden Phänomens.

Viele räumlich ausgedehnte Phänomene lassen sich mathematisch durch partielle Differentialgleichungen (*PDE*) charakterisieren. Dieser Beitrag konzentriert sich auf die Erfassung von linearen Phänomenen in der Ebene, wie beispielsweise *Diffusions-Advektions- oder Wärmeleitung*phänomenen, welche durch eine lineare PDE der Form

$$\mathbb{L}\left(p(\underline{z}, t), \frac{\partial p}{\partial t}, \dots, \frac{\partial^i p}{\partial t^i}, \frac{\partial p}{\partial z_x}, \dots, \frac{\partial^j p}{\partial z_x^j}, \frac{\partial p}{\partial z_y}, \dots, \frac{\partial^k p}{\partial z_y^k}\right) = s(\underline{z}, t)$$

beschrieben werden. Der Term $s(\underline{z}, t)$ bezeichnet dabei die von der Phänomenquelle pro Zeit- und Raumpunkt eingebrachte Anregung.

Zur Lösung von linearen PDEs werden in der modellbasierten Rekonstruktion Diskretisierungsverfahren genutzt. In diesem Beitrag wird die Raumdiskretisierung durch die *Finite Elemente Methode* [9] und die Zeitdiskretisierung durch das Crank-Nicolson-Verfahren erreicht [10].

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 $p(\underline{z}, t)$ als Reihe entwickelt und über die Summe

$$p(\underline{z}, t) \approx \sum_{i=0}^N \Phi_i(\underline{z}) \cdot x_i(t) \quad (15.1)$$

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 raumdiskretisierte 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 Differentialgleichungen in der Zustandsraumform

$$\underline{x}_k = \mathbf{A} \cdot \underline{x}_k + \mathbf{B} \cdot \underline{s}_k \quad (15.2)$$

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 $\underline{z}_n$ zum Zeitpunkt t_k aus dem Zustandsvektor $\underline{x}_k$ nach Gleichung (15.1) gemäß $p(\underline{z}_n, t_k) = \underline{\Phi}(\underline{z}_n) \cdot \underline{x}_k$ interpolieren, wobei $\underline{\Phi} := [\Phi_0, \Phi_1, \dots, \Phi_N]$.

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 (15.1) und (15.2) durch Interpretation des Zustandsvektors als Zufallsvektor in eine stochastische Form überführt und als *Mess-* und *Systemmodell* genutzt.

Abbildung 15.2 zeigt beispielhaft die Ergebnisse der modellbasierten Rekonstruktion eines eindimensionalen Temperaturverlaufs zu verschiedenen Zeitpunkten t_k . Dabei wird sowohl die Annäherung des rekonstruierten Verlaufs (*grün*) an die vorgegebene Temperatur (*blau*) als auch die Reduktion der Schätzunsicherheit (3σ -Grenze, *schwarz*) deutlich.

3 Lokalisierung als Schätzproblem

Im Bisherigen wurde eine Phänomenrekonstruktion auf Basis eines linearen Systemmodells und einer bekannten Anregungsfunktion durchgeführt. Um nun eine *Lokalisierung von Phänomenquellen* zu ermöglichen, muss das Systemmodell auf unbekannte Anregungsfunktionen erweitert werden. Dazu können parametrische Anregungsfunktionen definiert werden, welche die von einer Quelle erzeugte Anregung in Abhängigkeit der Quellenposition $\underline{z}_k^Q$ darstellen.




Abbildung 15.2: Rekonstruktion (grün) eines 1D-Temperaturverlaufs (blau) aus Messungen (orange) von Sensoren (rot).

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 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. Dabei muss simultan zur Rekonstruktion der Phänomenverteilung die Position der Quelle geschätzt werden, und zwar wie bisher ausschließlich auf Grundlage der gemessenen Phänomenwerte.

Zustandserweiterung Das Parameterschätzproblem wird in diesem Beitrag durch eine Zustandserweiterung gelöst, welche die Quellenposition als unbekannte Variable in den erweiterten Systemzustand $\tilde{\underline{x}}_k := [\underline{x}_k, \underline{z}_k^Q]^T$ 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 $\tilde{\underline{x}}_k$ als Zufallsvektor durch eine Dichtefunktion dargestellt wird, welche in jedem Verarbeitungsschritt durch Prädiktion zeitlich mit anfallenden Messwerten synchronisiert werden muss. Für nichtlineare Systemmodelle kann dabei die aus




Abbildung 15.3: Prinzip der Dichteapproximation im Gaußfilter.

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* [11, 12] als eine Erweiterung des Kalman-Filters genutzt. Das prinzipielle Vorgehen dieses Filters ist in Abb. 15.3 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 transformiert. Als Ergebnis kann dann die prädierte Zustandsdichte approximativ aus den transformierten Sigmapunkten berechnet werden. Die Vorteile des Gaußfilters liegen dabei in einer effizienten Berechnung der Sigmapunkte und der Möglichkeit, die nichtlinear zu verarbeitenden Zustandsdimensionen durch Dekomposition reduzieren zu können. Um beliebige Dichtefunktionen darstellen zu können, kann das Gaußfilter weiterhin ohne großen Aufwand auf ein Gaußmischdichte-Filter erweitert werden.

Zur Demonstration der entwickelten Verfahren wurde eine simulierte Quellenverfolgung durchgeführt. Wie in Abb. 15.4(a) gezeigt, bewegt sich hierbei eine Quelle auf einem begrenzten Gebiet, welches von zwei stationären Sensornetzen mit jeweils 9 bzw. 25 gleichzeitig aktiven Sensorknoten überwacht wird. Die in Abb. 15.4(b) 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.




Abbildung 15.4: Modellbasierte schritthaltende Quellenlokalisierung.

4 Verfolgung als Planungsproblem

Nachdem vorausgehend die schritthaltende Lokalisierung von Quellen vorgestellt wurde, 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 an den Ergebnissen in Abbildung 15.4(b) 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 mobiler Sensoren zu maximieren. Prinzipiell muss dazu für einen Sensor in jedem Zeitschritt aus einer (endlichen) Menge der möglichen Messpositionen diejenige Position u_k^S ausgewählt werden, welche zur höchsten Lokalisierungsgenauigkeit führt.

Wird eine Quellenverfolgung über einen längeren Zeitraum durchge-

führt, 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, welches 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* [11] genutzt. Dieses Verfahren stellt eine Erweiterung der linearen Einsatzplanung dar, welche sich im Fall von Systemen mit linearen System- und Messmodellen und gaußverteilten Unsicherheiten anwenden lässt.

Die *lineare Einsatzplanung* zeichnet sich dabei durch den Vorteil aus, dass sich für kovarianzbasierte Gütemaße die Entwicklung der Güte über den Beobachtungszeitraum unabhängig von den tatsächlichen Messwerten und somit bereits im Voraus berechnen lässt [13]. 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, wie beispielhaft in Abb. 15.5(a) für zwei mögliche Messpositionen $\underline{u}_k^{S,1}$, $\underline{u}_k^{S,2}$ pro Zeitschritt und für $L = 2$ dargestellt.

Um diese Suche möglichst effizient zu gestalten, lassen sich Pruning-Techniken nutzen [14]. 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 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





Abbildung 15.5: Lineare und nichtlineare Einsatzplanung.


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 Abb. 15.5(b) illustriert. Der prädizierte Systemzustand $\tilde{\mathbf{x}}_{k+j}$ wird dabei für alle j im Planungshorizont $\{1, 2, \dots, P\}$ über eine sogenannte Linearisierungstrajektorie von Sigmapunkten berechnet. Ausgehend vom aktuellen Systemzustand $\tilde{\mathbf{x}}_k$ wird dessen Dichte (1) durch eine Gaußdichte approximiert (2) und anschließend durch eine Menge von Sigmapunkten $\underline{\sigma}_{i,k}$ dargestellt (3). 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 Zustandstrajektorie kann anschließend das nichtlineare System- und Messmodell durch *statistische lineare Regression* für jeden Planungsschritt einzeln linearisiert werden. Das lineare Systemmodell im Zeitschritt t_{k+j} wird dabei beispielsweise durch Bestimmung einer linearen Abbildung zwischen den beiden durch die Sigmapunktmengen $\{\underline{\sigma}_{i,k+j-1}\}$ und $\{\underline{\sigma}_{i,k+j}\}$ repräsentierten Zufallsvektoren approximiert.

Zum Abschluss dieses Abschnitts werden die *Ergebnisse einer simulierten Quellenverfolgung* mit einem einzelnen mobilen Sensor präsentiert.



(a) Prozentuale Lokalisierungsgenauigkeit für vier Planungshorizonte.



(b) Bewegungstrajektorie der Quelle (blau) und des mobilen Sensors (rot).

Abbildung 15.6: Modellbasierte Quellenverfolgung mit einem mobilen Sensor.

Dazu wird das bereits in Abschnitt 3 beschriebene Setup wiederverwendet, hier über 150 Zeitschritte. In Abb. 15.6(a) ist die prozentuale Lokalisierungsgenauigkeit, bezogen auf die Größe des überwachten Gebiets, für unterschiedliche Planungshorizonte der Länge 1 bis 3 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 Abb. 15.6(b) sind weiterhin die Bewegungstrajektorien des mobilen Sensors und der Quelle abgebildet. Dabei ist zu erkennen, wie der Sensor das zu überwachende Gebiet anfänglich großräumig abfährt, um dann mit ansteigender Lokalisierungsgüte die Quelle in engen Kreisen zu verfolgen, bedingt durch die größere Sensorgeschwindigkeit.

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*, Vol. 40, S. 102–114, Aug. 2002.
2. M. E. Alpay und M. H. Shor, „Model-based solution techniques for the source localization problem“, *IEEE Transactions on Control Systems Technology*, Vol. 8, S. 895–904, 2000.
3. J. Matthes, *Eine neue Methode zur Quellenlokalisierung auf der Basis räumlich verteilter, punktwieser 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, Minnesota, USA, Jun. 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, Deutschland, Jul. 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*, Vol. 2, Oct. 1994, S. 765–769.
7. F. Sawo, *Nonlinear State and Parameter Estimation of Spatially Distributed Systems*. Dissertation, Universität Karlsruhe (TH), 2009.
8. 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.
9. A. J. Baker, *Finite Element Computational Fluid Mechanics*. Taylor and Francis, 1983.
10. 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*, Vol. 6, Nr. 1, S. 207–226, 1996.

11. M. Huber, *Probabilistic Framework for Sensor Management*. Dissertation, Universität Karlsruhe (TH), 2009.
12. 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*, Vol. 17, Seoul, Südkorea, Jul. 2008.
13. L. Meier, J. Peschon und R. M. Dressler, „Optimal control of measurement subsystems“, *IEEE Transactions on Automatic Control*, Vol. 12, Nr. 5, S. 528–536, Oct. 1967.
14. M. F. Huber und U. D. Hanebeck, „Priority list sensor scheduling using optimal pruning“, in *Proceedings of the 11th International Conference on Information Fusion (Fusion 2008)*, Köln, Deutschland, Jul. 2008.
15. M. Morari und J. H. Lee, „Model Predictive Control: Past, Present and Future“, *Computers and Chemical Engineering*, 1997.