



Objektdetektion und -verfolgung durch nichtlineare Filterung und Fusion von Lidar- und Positionsdaten

Object Detection and Tracking through Non-Linear Filtering and Fusion of Lidar and Position Data

Michael Thuy, Karlsruher Institut für Technologie,
Julian Habigt, Technische Universität München,
Fernando Puente León, Karlsruher Institut für Technologie

Zusammenfassung In diesem Beitrag wird eine neue Methode erarbeitet, um Objekte im Kontext von Fahrerassistenzsystemen und autonomen Automobilen zu erkennen und robust zu verfolgen. Als umweltabbildende Sensoren dienen zwei Lidarscanner, welche das Fahrzeugumfeld zyklisch abtasten. Zusätzlich werden diese Daten mit den eigenen Positionsdaten fusioniert, um sie in ein weltfestes Koordinatensystem zu überführen. Diese Lidardaten werden anschließend einem Partikelfilter zugeführt. Innerhalb des Filterzyklus dienen die Lidarpunkte zur Speisung der Beobachtungsfunktion und bewerten somit die einzelnen Partikel. Eine darauf folgende Ballungsanalyse extrahiert die geschätzten Systemzustände der verfolgten Objekte.

Summary This article presents a new method of object detection and tracking in the context of driver assistance systems and autonomous automobiles. Two lidar scanners that scan the environment periodically serve as the data source. The sensors' raw data is then fused with high precision positioning data in order to transform it into a global coordinate system. Then, the transformed data is used to feed the particle filter. Within this filter, an importance function evaluates the newly gained lidar points to weigh the individual particles. Finally, a cluster analysis in the observation space extracts the estimated object states.

Schlagwörter Objekterkennung, Objektverfolgung, Datenfusion, Partikelfilter, Laser-Scanner, modellgestütztes Messen

Keywords Object detection, object tracking, data fusion, particle filter, laser scanner, model-based measurement

1 Einleitung

Die Objektdetektion und -verfolgung im Fahrzeugumfeld ist ein essenzieller Bestandteil heutiger sowie zukünftiger Fahrerassistenzsysteme. In der Literatur findet man eine große Anzahl an Arbeiten, die unter dem Einsatz verschiedener Sensorprinzipien versuchen, eine robuste Objektdetektion und eine anschließende Verfolgung zu

implementieren. Die Ableitung von Objekthypothesen mit Hilfe eines monokularen Ansatzes wird in [1] beschrieben. In [2;3] werden die Hypothesen mit einem Stereo-Ansatz erzeugt. Da das Ergebnis und nicht zuletzt die Güte der bildverarbeitenden Prozesse in der Praxis sehr oft von den vorherrschenden Umgebungsbedingungen abhängt, führt die zusätzliche Benutzung von

komplementären Sensoren zu einer signifikanten Steigerung der Systemrobustheit [4; 5]. Der Gebrauch von aktiven Sensoren, wie beispielsweise eines Lidarscanners, verringert diese Abhängigkeit drastisch. Da der Sensor die Szene mit Hilfe eines schmalbandigen Laserstrahles abtastet, wird der Einfluss des Umgebungslichtes stark reduziert. Ein weiterer Vorteil dieser Sensorart ist, dass sie nur Punkte liefert, wenn der Laserstrahl tatsächlich ein potenzielles Objekt getroffen hat. Somit stellt jeder erfasste Punkt per se ein Teil eines Objektes dar.

Der vorliegende Beitrag präsentiert einen neuen Ansatz, um Objekte im Fahrzeugumfeld zu detektieren und zu verfolgen. Für die Konstruktion des dafür notwendigen Zustandsbeobachters benötigt man ein – zunächst frei wählbares – unterlagertes dynamisches Modell. Um den realen physikalischen Gegebenheiten bestmöglich zu entsprechen, fällt dabei die Wahl auf ein nichtlineares Modell. In Kombination mit einem erweiterten Kalman-Filter lässt sich damit ein Verfolgungsfilter implementieren [6]. Dabei wird aber jedem verfolgten Objekt ein eigenes Filter gewidmet, welches die Systemzustände zyklisch schätzt. In unserem Beitrag stellen wir eine auf einem Partikelfilter basierende Lösung vor, welche die Funktion der Detektion und Zustandsschätzung übernimmt. Anders als die in [7–11] vorgestellten Ansätze lässt diese Methode die direkte Benutzung von Lidar-Rohdaten zu [12]. Das Filter übernimmt dann neben der Prädiktion der Systemzustände ebenfalls auch die Assoziation von bekannten und neu erkannten Objekten. Zudem benötigt man nur ein Filter, welches durch die Abtastung einer beliebig gearteten Wahrscheinlichkeitsdichtefunktion (WDF) in der Lage ist, mehrere Objekte zu verfolgen.

2 Sensoranordnung und Datenregistrierung

Für das weitere Verständnis ist es wichtig, die verwendete Sensoranordnung vorzustellen. Für die Umfeldwahrnehmung werden zwei unabhängige Einzel-Laserscanner benutzt. Beide Sensoren sind, wie in Bild 1 gezeigt, jeweils an der Front- und Heckstoßstange montiert. Dabei sind sie so justiert, dass bei einem ruhig stehenden Fahrzeug die beiden Scanebenen parallel zum Untergrund angeordnet sind. Beide Sensoren tasten das Umfeld mit einer Winkelauflösung von einem halben Grad ab.

Der nächste wichtige Punkt ist die Registrierung der Daten in einem örtlichen und zeitlichen Bezug. Da die beiden Sensoren über eine elektrische Verbindung in ihrem Scanvorgang synchronisiert werden, sind die Daten

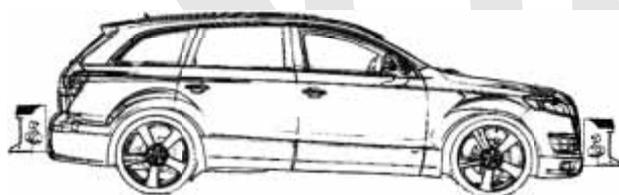


Bild 1 Versuchsträger mit Lidarsensoren an Front- und Heckstoßstange.

zeitlich bereits synchron. Beide Sensoren sind bezüglich des Fahrzeugreferenzpunkts kalibriert. Insofern beschreiben die gemessenen Lidarpunkte das Umfeld aus relativer Sicht des Testfahrzeugs. Um nun einen weltfesten Bezug herzustellen, bedarf es der exakten Position und Ausrichtung des Eigenfahrzeugs. Eine Objektverfolgung, die auf relativen Daten operiert, muss demnach der Überlagerung aus der Eigen- und der Fremdbewegung folgen. Somit überlagern sich zwei reale Bewegungen, die von einem Modell nur unter größeren Fehlern abgedeckt werden können. Aus diesem Grund fusionieren wir die Daten einer Inertialplattform, kombiniert mit einem differenziellen Satellitenortungssystem. Diese Einheit liefert die aktuelle Position in Längen- und Breitengrad sowie die derzeitige Höhe. Zusätzlich erhält man die aktuelle Ausrichtung des Fahrzeugs. Mit Hilfe dieser Angaben lassen sich die Lidardaten in ein weltfestes Koordinatensystem überführen. Als ein solches Koordinatensystem wählen wir UTM-Koordinaten.

3 Grundlagen und Methoden

In diesem Abschnitt werden die Grundlagen des Filterentwurfs dargestellt.

3.1 Allgemeine Formulierung der

A-posteriori-Wahrscheinlichkeitsdichtefunktion

Der Monte-Carlo-Ansatz kann als eine spezielle Lösung des allgemeinen Problems der Prädiktion von Zustandsvariablen bzw. der Objektverfolgung verstanden werden. Diesen Aufgabenstellungen liegt dasselbe Problem zugrunde: die Bestimmung der resultierenden A-posteriori-WDF, basierend auf allen zur Verfügung stehenden Messungen

$$p(\mathbf{X}_k | \mathbf{Z}_k), \tag{1}$$

wobei hier \mathbf{X}_k die Gesamtheit aller Zustandsvektoren $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ vergangener Zeitpunkte bis zum aktuellen Zeitpunkt k umfasst:

$$\mathbf{X}_k = (\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_k). \tag{2}$$

Analog dazu beinhaltet der Beobachtungsvektor \mathbf{Z}_k alle Beobachtungsgrößen vergangener Zeitpunkte bis zum momentanen Zeitpunkt k .

Legt man nun einen Markov-Prozess zugrunde, so lässt sich unter Zuhilfenahme der konkreten Likelihood-Funktion $p(\mathbf{z}_k | \mathbf{x}_k)$ die Bayes'sche Regel

$$p(\mathbf{x}_k | \mathbf{Z}_k) = \frac{p(\mathbf{z}_k | \mathbf{x}_k) \cdot p(\mathbf{x}_k | \mathbf{Z}_{k-1})}{p(\mathbf{z}_k | \mathbf{Z}_{k-1})} \tag{3}$$

anwenden. Damit erhält man die gesuchte A-posteriori-WDF. Für den Prädiktionsschritt ergibt sich die gesuchte WDF

$$p(\mathbf{x}_k | \mathbf{Z}_{k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}) \cdot p(\mathbf{x}_{k-1} | \mathbf{Z}_{k-1}) d\mathbf{x}_{k-1} \tag{4}$$

durch Integration. Aus theoretischer Sicht ist das eingangs aufgegriffene Problem gelöst. Doch blickt man auf

Gleichung (4), so erkennt man ein mehrdimensionales Integral, welches eine unendliche Anzahl an Beobachtungsvektoren \mathbf{Z}_{k-1} berücksichtigt. Ausgehend von dieser Feststellung liefert der im Folgenden präsentierte Ansatz eine Möglichkeit, das Integral tatsächlich zu lösen.

3.2 Der Monte-Carlo-Ansatz

Der zugrunde liegende Ansatz ist die Darstellung der A-posteriori-WDF durch eine definierte Menge an Partikeln. Jedes Partikel kann somit als ein Satz an Zustandsvektoren mit ihren entsprechenden Gewichten verstanden werden. Werden N Partikel mit ihren Zustandsvektoren $\{\mathbf{X}_k^i, i = 0, \dots, N\}$ eingesetzt, so können die Gewichte wie folgt bestimmt werden:

$$w_k^i \sim \frac{p(\mathbf{X}_k^i | \mathbf{Z}_k)}{q(\mathbf{X}_k^i | \mathbf{Z}_k)}, \quad (5)$$

wobei $q(\cdot)$ die Gewichtungverteilung darstellt. Eine weitere Entwicklung der obigen Formel führt schließlich auf die iterative Berechnung der Gewichte

$$w_k^i \sim w_{k-1}^i \cdot \frac{p(\mathbf{z}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_k)}. \quad (6)$$

Für den Fall, dass die Zustandsänderung nicht von der Beobachtung abhängt, reduziert sich Gleichung (6) auf

$$w_k^i \sim p(\mathbf{z}_k | \mathbf{x}_k^i). \quad (7)$$

Somit ist die Konstruktion der Likelihood-Funktion von essenzieller Bedeutung. Im nächsten Kapitel wird insbesondere dieser Tatsache Rechnung getragen.

4 Filterentwurf

4.1 Dynamisches Prozessmodell

Die Konfiguration eines Fahrzeugs bzw. eines Partikels i wird zum Zeitpunkt k durch einen 6-dimensionalen Zustandsvektor

$$\mathbf{x}_k^i = [x \ y \ \varphi \ v \ l \ w]^T \quad (8)$$

beschrieben, welcher Informationen über den Ort x, y eines erkannten Fahrzeugs, den Winkel der Bewegungsrichtung φ und die Geschwindigkeit des Fahrzeugs v in Fahrtrichtung enthält, sowie zwei Parameter l und w , welche die Länge und Breite des Fahrzeugs repräsentieren.

Die Entwicklung des Zustands eines Fahrzeugs von einem Zeitpunkt zum nächsten innerhalb eines Zeitintervalls Δt wird durch das Prozessmodell

$$\mathbf{x}_k^i = \begin{bmatrix} 1 & 0 & 0 & \Delta t \sin \varphi & 0 & 0 \\ 0 & 1 & 0 & \Delta t \cos \varphi & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{x}_{k-1}^i + \begin{bmatrix} \sigma_x \\ \sigma_y \\ \sigma_\varphi \\ \sigma_v \\ \sigma_l \\ \sigma_w \end{bmatrix} \quad (9)$$

beschrieben. Es wird dabei davon ausgegangen, dass sich das Fahrzeug mit konstanter Geschwindigkeit v in

Richtung des zuvor geschätzten Kurses φ weiterbewegt. Diese präzidierte Position wird dann mit normalverteiltem Rauschen überlagert, um eine unvollkommene Modellierung – etwa aufgrund der nicht berücksichtigten Beschleunigung des Fahrzeugs – sowie andere unvorhergesehene Bewegungen abzubilden. Alle anderen Zustandsgrößen werden als konstant angenommen.

4.2 Generierung der Bewertungsfunktion

Das Beobachtungsmodell in Form der Likelihood-Funktion $p(\mathbf{z}_k | \mathbf{x}_k^i)$ beschreibt, wie sich ein bestimmter Objektzustand \mathbf{x}_k^i in den Messwerten \mathbf{z}_k niederschlägt. Im vorliegenden Fall drückt diese WDF die Wahrscheinlichkeit aus, dass der Laserstrahl an einem bestimmten Ort $\mathbf{z} = (\hat{x}, \hat{y})$ im Scanbereich von einem Fahrzeug mit dem hypothetischen Zustand \mathbf{x}_k^i reflektiert wird.

Dafür wird die Form eines Fahrzeugs, welches durch den Zustandsvektor \mathbf{x}_k^i definiert ist, in einem Modell $\xi(\mathbf{z}_k, \mathbf{x}_k^i)$ abgebildet. Dieses Modell entspricht noch nicht der Beobachtungsfunktion $p(\mathbf{z}_k | \mathbf{x}_k^i)$, sondern vielmehr einer Bewertungsfunktion, mit der jeder einzelne Messpunkt z_k^n der beiden Laserscanner bewertet wird.

Die gesuchte WDF $p(\mathbf{z}_k | \mathbf{x}_k^i)$ ergibt sich dann aus der nichtnegativen Summe der Bewertungen aller Scanpunkte

$$p(\mathbf{z}_k | \mathbf{x}_k^i) = \begin{cases} \sum_{n=1}^M \xi(z_k^n), & \text{falls } \sum_{n=1}^M \xi(z_k^n) > 0 \\ 0 & \text{sonst} \end{cases} \quad (10)$$

mit der Anzahl der Messpunkte M . Die Normierung der so gewonnenen WDF findet im Resampling-Schritt des Partikelfilters statt.

4.3 Formmodellierung

Das Fahrzeug wird in der Bewertungsfunktion $\xi(z_k^n, \mathbf{x}_k^i)$ als rechteckiges Objekt modelliert, wobei alle vier Kanten des Fahrzeugs durch Gaußfunktionen, welche entlang der entsprechenden Kanten verteilt sind, beschrieben werden.

Die Front- und Hecklinie des Fahrzeugs mit ihrer Breite w werden entlang der x -Achse durch

$$\xi_{1,1/3}(z_k^n, \mathbf{x}_k^i) = \begin{cases} \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{\tilde{y} \pm \frac{l}{2}}{\sigma}\right)^2\right) & \forall \tilde{x} \in \left[-\frac{b}{2}, \frac{b}{2}\right] \\ 0 & \text{sonst} \end{cases} \quad (11)$$

beschrieben, die beiden Seitenlinien mit der Länge l durch

$$\xi_{1,2/4}(z_k^n, \mathbf{x}_k^i) = \begin{cases} \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{\tilde{x} \pm \frac{b}{2}}{\sigma}\right)^2\right) & \forall \tilde{y} \in \left[-\frac{l}{2}, \frac{l}{2}\right] \\ 0 & \text{sonst.} \end{cases} \quad (12)$$

Dieses Modellkoordinatensystem \tilde{x}, \tilde{y} wird anschließend noch durch eine Koordinatentransformation an den Ort und die Richtung des hypothetischen Fahrzeuges, wie es im Zustandsvektor beschrieben wird, transformiert.

Sollte nun der hypothetische Zustand \mathbf{x}_i des Partikels genau dem Zustand des verfolgten Fahrzeuges entsprechen, so werden alle Messpunkte, die von diesem Fahrzeug reflektiert werden, im Modell an der Position der modellierten Kanten liegen. Nach den Gleichungen (11) und (12) werden dadurch diese Messpunkte mit hohen Gewichten bewertet werden, weshalb nach Gleichung (10) auch das Partikel ein hohes Gewicht erhält. Bei einer falschen Hypothese werden die Messpunkte und das Modell nicht übereinstimmen, sodass diesem Partikel nur ein geringes Gewicht zugeordnet wird.

4.4 Sichtbarkeitsmodellierung

In einem tatsächlichen Scan können allerdings nie alle vier Kanten des Fahrzeuges gleichzeitig sichtbar sein, da mindestens zwei Kanten des Fahrzeuges verschattet sind und diese daher im Scan nicht auftauchen. Dadurch entstehen im Scan sogenannte *L-Shapes* als charakteristische Merkmale.

Zur Modellierung dieses Verhaltens wird der Winkel β berechnet, unter welchem der Laserstrahl auf die Kante des hypothetischen Fahrzeuges auftrifft. Der Kosinus dieses Winkels liefert dann die gewünschte Gewichtung I bezüglich der Sichtbarkeit der entsprechenden Kante. Sollte dieser Kosinus negativ werden, so zeigt dies, dass die betroffene Kante aus Sicht des Laserscanners verdeckt ist. Durch Multiplikation mit der Heaviside-Sprungfunktion $\Theta(\cdot)$ wird in diesem Fall die Kante nicht gewichtet:

$$I = \cos(\beta) \cdot \Theta(\cos(\beta)). \tag{13}$$

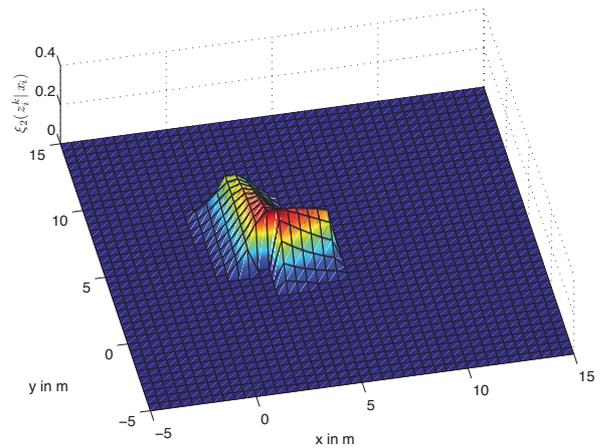
Die Bewertungsfunktion ξ_1 lässt sich mit diesem Wissen nun zur neuen Bewertungsfunktion

$$\xi_2(z_k^n, \mathbf{x}_k^i) = \xi_1(z_k^n, \mathbf{x}_k^i) \cdot I(z_k^n, \mathbf{x}_k^i) \tag{14}$$

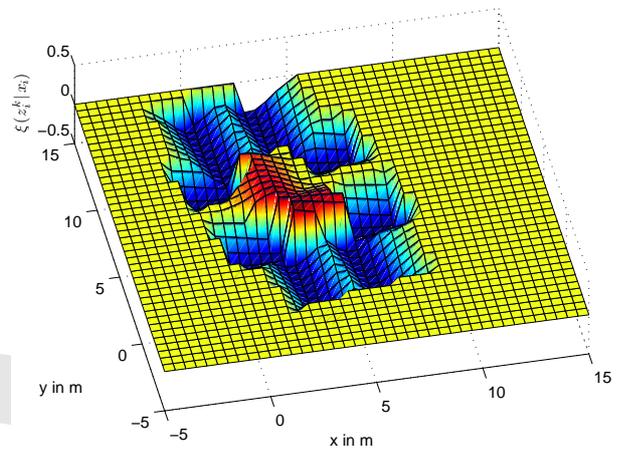
erweitern. Bild 2a zeigt ein Beispiel der Bewertungsfunktion ξ_2 .

4.5 Unterdrückung von Leitplanken

Abschließend muss noch verhindert werden, dass im Laserscan vorhandene Geradenstücke, wie sie beispielsweise durch Leitplanken am Straßenrand verursacht werden, als Kanten eines Fahrzeuges detektiert werden. Dazu werden die modellierten Kanten $\xi_{1,x}$ und $\xi_{1,y}$ des Fahrzeuges an beiden Enden jeweils um eine Fahrzeuglänge und -breite erweitert, allerdings diesmal mit entsprechend negativen Gewichten versehen. Diese Kanten werden nun als ξ_3 bezeichnet. Dadurch werden Geraden, die länger als das modellierte Fahrzeug sind, wieder geringere Gewichtungen erfahren, da deren Messpunkte gemäß Gleichung (10) die WDF $p(z_i|\mathbf{x}_i)$ wieder verringern und



(a) Modellierung der Sichtbarkeit der Kanten des Fahrzeuges.



(b) Negative Gewichtung in der Verlängerung der entsprechenden Kanten zur Unterdrückung zu langer Geradenstücke.

Bild 2 Entstehung des Beobachtungsmodells.

dadurch auch das entsprechende Partikel eine geringere Gewichtung erfährt.

Die gesamte Bewertungsfunktion $\xi(z_k^n, \mathbf{x}_k^i)$ setzt sich dann aus der Summe der jeweils betragsmäßig größten Kanten zusammen und ist in Bild 2b exemplarisch dargestellt.

4.6 Normierung der Beobachtungsfunktion

Als letzter Schritt wird die Beobachtungsfunktion normiert, um die unterschiedlich hohen Gewichtungen, die verschieden große Fahrzeuge erfahren würden, auszugleichen. Weiterhin wird auch die Abnahme der Gewichtungen mit zunehmender Distanz des Fahrzeuges zum Laserscanner aufgrund der Abtastung mit gleich bleibenden Winkelabständen korrigiert.

4.7 Clustering der Partikel

Bild 3 zeigt die Partikelverteilung der Position, wenn sich drei Fahrzeuge im Erfassungsbereich der Laserscanner befinden. Es ist eine Häufung der Partikel an den drei

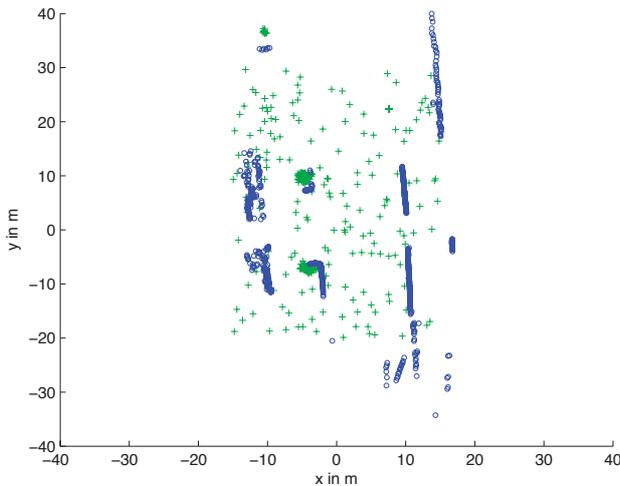


Bild 3 Der Plot zeigt exemplarisch die Verteilung der Partikel im eingeschwungenen Zustand (Anzahl der Partikel: $N = 1000$).

Fahrzeugen zu erkennen. Außerdem sieht man, dass Partikel geringen Gewichts immer wieder zufällig über den Suchraum verteilt werden, um auch neu hinzukommende Fahrzeuge zuverlässig erkennen zu können.

Um die gewonnenen Informationen über die drei Fahrzeuge ausgeben zu können, ist es nun noch nötig, die Partikel zu clustern. Dazu wird der *k-means-Algorithmus* eingesetzt. Die Partikel werden dabei in einzelnen Clusterzentren zusammengefasst und es wird der Zustandsvektor mit der jeweils höchsten Gewichtung, sofern diese einen einstellbaren Schwellwert überschreitet, ausgegeben.

5 Ergebnisse

5.1 Evaluierung der Beobachtungsfunktion

Bild 4 zeigt das Ergebnis der Beobachtungsfunktion als dreidimensionalen Plot über einem exemplarisch gewählten Messdatensatz. Gut zu erkennen sind das eindeutige Maximum am Aufenthaltsort des Fahrzeugs im Scan sowie der stetige Abfall in der Umgebung dieses Maximums.

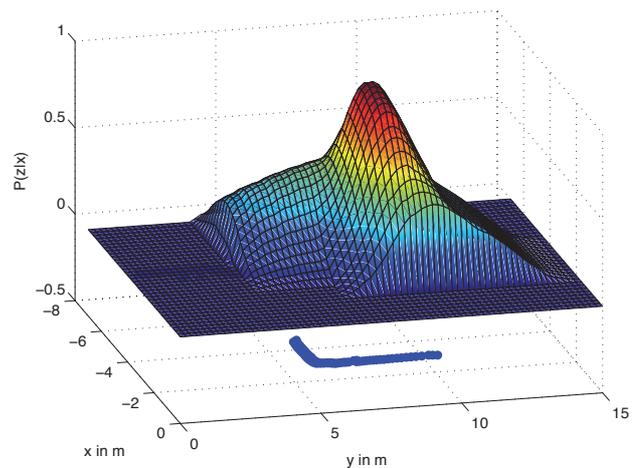


Bild 4 Beobachtungsfunktion für verschiedene angenommene Positionen x, y über einem exemplarisch gewählten Messdatensatz.

In den Bildern 5a und 5b wird gezeigt, wie sich die Beobachtungsfunktion verhält, wenn die Parameter Länge bzw. Breite verändert werden. Hier ist ebenfalls wieder ein eindeutiges Maximum mit stetig abfallenden Gewichtungen bei Abweichungen von diesem Maximum zu erkennen.

Als Letztes ist in Bild 5c noch ein Plot über den Winkel dargestellt. Gut zu erkennen ist eine Periodizität bei 180° – schließlich kann aus einem einzelnen Frame keine Information über die Bewegungsrichtung des Fahrzeugs gewonnen werden. Dadurch entstehen zwei Maxima in der Winkelverteilung der Partikel. Allerdings verschwinden die Partikel mit falscher Bewegungsrichtung schon nach wenigen Frames, wenn das Prozessmodell angewendet wurde und sich die Partikel immer weiter vom gemessenen Fahrzeug entfernen.

5.2 Fehler

Im Folgenden wird der Fehler des Filters im Vergleich zu einem weiteren Verfahren auf der Basis eines erweiterten Kalman-Filters ausgewertet. Dazu wurde die längste

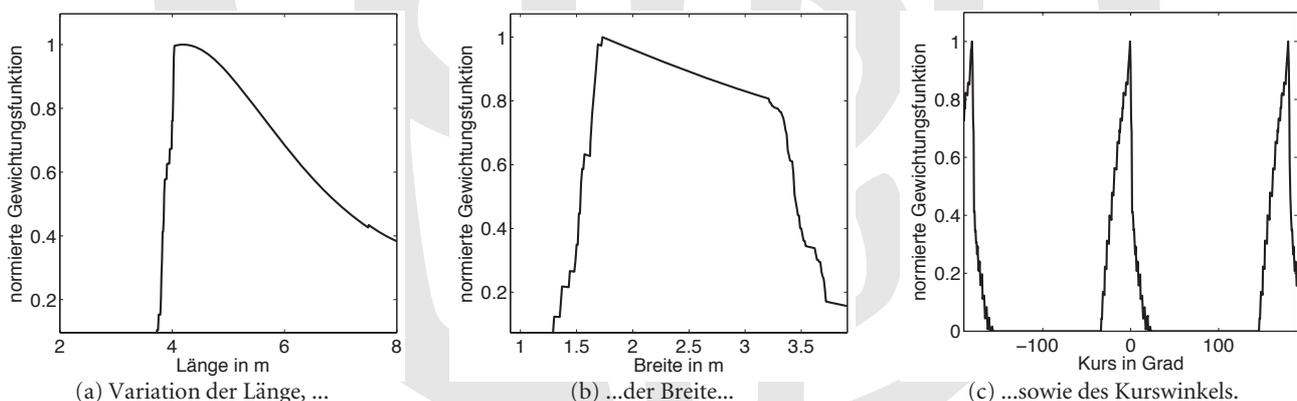


Bild 5 Die Diagramme zeigen das Verhalten der Gewichtungsfunktion, wenn jeweils ein Parameter (Länge, Breite oder Kurs) verändert wird. Die restlichen Parameter wurden dabei auf dem korrekten Wert festgehalten.

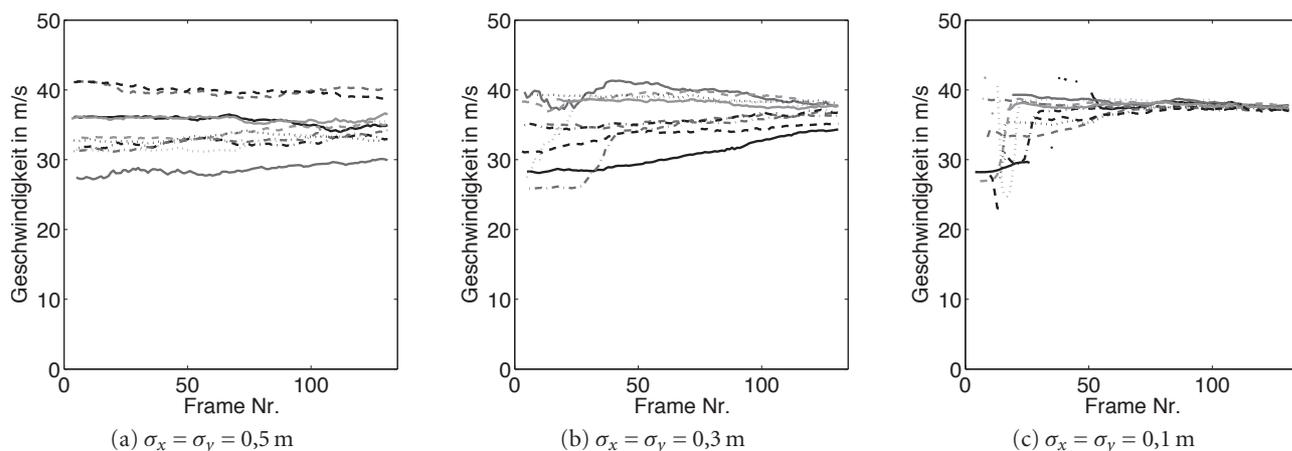


Bild 6 Verteilung der geschätzten Geschwindigkeit des Fahrzeugs v für jeweils zehn Durchläufe des Filters in Abhängigkeit von σ_x und σ_y .

aufgezeichnete Testsequenz gewählt (22 Sekunden mit 825 Frames), wobei in 561 dieser Frames ein Fahrzeug in den Scans zu erkennen ist. Bei beiden Filtern wurde jeweils die Anzahl der Frames gezählt, in denen das Fahrzeug korrekt erkannt bzw. fälschlicherweise nicht erkannt wurde und schließlich noch die Anzahl der Frames, in denen ein Fahrzeug erkannt wurde, welches eigentlich keines ist. Im letzteren Fall wurde jedes Frame so oft gezählt, wie falsch erkannte Fahrzeuge darin vorhanden waren.

Beide Filter haben in diesem Vergleich die vorhandenen Fahrzeuge sehr zuverlässig erkannt: das vorgestellte Filter in 96,4% der Frames, das Vergleichsfilter in 98,0%. Unser Filter weist allerdings im Vergleich zum EKF eine deutlich niedrigere Zahl von Falschalarmen auf (43 zu 556), d.h. Letzteres erkennt sehr häufig tatsächlich nicht vorhandene Fahrzeuge. Das hier vorgeschlagene Filter ist aufgrund der recht aufwendigen Modellierung der Form des Fahrzeugs in der Beobachtungsfunktion deutlich robuster gegenüber derartigen Falschalarmen. Das Vergleichsfilter weist dagegen eine etwas kleinere Zahl falsch negativer Ergebnisse auf (11 gegenüber 20), was daran liegt, dass es neu hinzukommende Fahrzeuge schneller erkennt. Das vorgestellte Filter benötigt dafür einige Frames, bis sich die Partikel an dem beobachteten Fahrzeug konzentrieren.

6 Zusammenfassung

In der vorliegenden Arbeit wurde ein neues Verfahren erarbeitet, welches auf der Grundlage eines einzigen Partikelfilters mehr als ein Fahrzeug verfolgen kann. Dabei werden durch die Einspeisung der Rohdaten alle zur Verfügung stehenden Informationen der Sensordaten ausgewertet.

Das Verfahren lässt sich problemlos durch Hinzunahme weiterer Sensoren und zusätzlicher Prozessmodelle erweitern. Auf diese Weise kann eine höhere Robustheit bzw. darüber hinaus eine indirekte Klassifikation der verfolgten Objekte erzielt werden.

Danksagung

Diese Arbeit wurde von der Deutschen Forschungsgemeinschaft (DFG) im Rahmen des Sonderforschungsbereiches SFB/TR-28 „Kognitive Automobile“ finanziert.

Literatur

- [1] C. Hoffman, T. Dang und C. Stiller, “Vehicle detection fusing 2d visual features”, in *Intelligent Vehicles Symposium, 2004 IEEE*, S. 280–285, Juni 2004.
- [2] M. Thuy und A. Sandmair, “Object classification based on stereo data”, in *Reports on Distributed Measurement Systems*, F. Puente León (Hrsg.), S. 141–154, Shaker Verlag, 2008.
- [3] A. Bachmann und T. Dang, “Multiple object detection under the constraint of spatiotemporal consistency”, in *Intelligent Transportation Systems Conference, 2006. ITSC '06. IEEE*, S. 295–300, Sept. 2006.
- [4] M. Thuy, A. Saber Tehrani und F. Puente León, “Bayes’sche Fusion von Stereobildfolgen und Lidardaten”, in *Bildverarbeitung in der Mess- und Automatisierungstechnik*, F. Puente und M. Heizmann (Hrsg.), *VDI-Berichte 1981*, S. 67–78, VDI Verlag, (Düsseldorf), 2007.
- [5] S. Wender und K. Dietmayer, “A feature level fusion approach for object classification”, in *Intelligent Vehicles Symposium, 2007 IEEE*, S. 1132–1137, Juni 2007.
- [6] A. Mendes, L. Bento und U. Nunes, “Multi-target detection and tracking with a laser scanner”, in *Intelligent Vehicles Symposium, 2004 IEEE*, S. 796–801, Juni 2004.
- [7] E. B. Koller-Meier und F. Ade, “Tracking multiple objects using the condensation algorithm”, *Robotics and Autonomous Systems* **31**, S. 93–105, 2001.
- [8] M. Marron, J. García, M. Sotelo, D. Fernandez und D. Pizarro, “Xpfc: an extended particle filter for tracking multiple and dynamic objects in complex environments”, in *Intelligent Robots and Systems, 2005. (IROS 2005). 2005 IEEE/RSJ International Conference on*, S. 2474–2479, August 2005.
- [9] J. Almeida und R. Araujo, “Tracking multiple moving objects in a dynamic environment for autonomous navigation”, in *Advanced Motion Control, 2008. AMC '08. 10th IEEE International Workshop on*, S. 21–26, März 2008.
- [10] M. Thuy und F. Puente León, “Non-linear, shape independent object tracking based on 2d lidar data”, in *Intelligent Vehicles Symposium, 2009 IEEE*, S. 532–537, Juni 2009.
- [11] M. Thuy und F. Puente León, “Non-linear multimodal object tracking based on 2d lidar data”, *Metrology & Measurement Systems XVI(3)*, S. 359–369, 2009.

- [12] M. Thuy, J. Habigt und F. Puente León, "Multi-objektverfolgung auf der Grundlage von Lidardaten", in *XXIII. Messtechnisches Symposium des Arbeitskreises der Hochschullehrer für Messtechnik e.V. (AHMT)*, G. Goch (Hrsg.), S. 181–192, Shaker Verlag, (Aachen), 2009.

Manuskripteingang: 3. Februar 2010, zur Veröffentlichung angenommen: 11. Februar 2010



Dipl.-Ing. Michael Thuy arbeitet am Institut für Industrielle Informationstechnik am Karlsruher Institut für Technologie im Themenbereich „Kognitive Automobile“. Im Rahmen seiner Forschungsarbeit befasst er sich insbesondere mit den Fragestellungen der Datenfusion und der Objekterkennung und -verfolgung.

Adresse: Institut für Industrielle Informationstechnik, Karlsruher Institut für Technologie, Hertzstraße 16, 76187 Karlsruhe, E-Mail: thuy@iit.uni-karlsruhe.de



Dipl.-Ing. Julian Habigt ist wissenschaftlicher Mitarbeiter am Lehrstuhl für Datenverarbeitung der Technischen Universität München.

Adresse: Lehrstuhl für Datenverarbeitung, Technische Universität München, Arcisstraße 21, 80333 München, E-Mail: julian.habigt@tum.de



Prof. Dr.-Ing. Fernando Puente León leitet das Institut für Industrielle Informationstechnik am Karlsruher Institut für Technologie. Hauptarbeitsgebiete: Mess- und Automatisierungstechnik, Signalverarbeitung, automatische Sichtprüfung und Bildverarbeitung, Mustererkennung, Informationsfusion und Datenübertragung.

Adresse: Institut für Industrielle Informationstechnik, Karlsruher Institut für Informationstechnik, Hertzstraße 16, 76187 Karlsruhe, E-Mail: puente@kit.edu

Vorschau auf Heft 5/2010

In unserem nächsten Heft finden Sie unter anderem folgende Themen:

- *Lanza, G., Peters, J.*: Werkstückeinfluss bei der Auswertung in der Koordinatenmesstechnik
- *Fritz, S., Murrenhoff, H., Siebertz, K.*: Zügige Vermessungsmethode für pneumatische Miniaturkomponenten
- *Gegner, J., Kuipers, U., Mauntz, M.*: Ölsensorsystem zur Echtzeit-Zustandsüberwachung von technischen Anlagen und Maschinen

Weitere Informationen über geplante Hefte, ausführliche Informationen über die in den letzten Heften der **tm** erschienenen Beiträge sowie Hinweise für Autoren finden Sie im Internet unter <http://www.tm-technisches-messen.de>.