

Ein Kontur schätzendes Kalmanfilter mithilfe der Evidenztheorie

Sebastian Ohl * und Markus Maurer †

Montag 14 Februar, 2011

Zusammenfassung: Im Projekt Stadtpilot (Wille u. a., 2009) wurde die im Urban Challenge Team CarOLO der TU Braunschweig (Rauskolb u. a., 2008) eingesetzte objektbasierte Umfeldwahrnehmung (Ohl, 2007) weiterentwickelt. Bedingt durch das veränderte Szenario wurde der Einsatzbereich des Versuchsträgers von abgesperrten Testgeländen in den öffentlichen Straßenverkehr verlagert.

In dieser veränderten Umgebung werden Fremdfahrzeuge von den eingesetzten Sensoren durch einen offenen Polygonzug (Kontur) mit einer Vielzahl von Stützpunkten beschrieben. Teilweise liegen sie auf Geraden oder bilden das Rauschen der Kontur ab und leisten so keinen Beitrag zur Beschreibung der Kontur. Diese überflüssigen Punkte erschweren ein erfolgreiches Tracking und verzerren die Kontur der Objekthypothese. Aufgrund des zahlreichen Fremdverkehrs, bedingt durch die Veränderung des Umfelds, treten ferner häufig Perspektivwechsel durch überholende und überholte Fahrzeuge auf. Aus diesem Grund erfahren einzelne Stützpunkte der Kontur keine weiteren Aktualisierungen durch Messungen und können so ebenfalls zu Verzerrungen der Kontur führen.

Um diesen Problemen zu begegnen, wurde das Kontur schätzende Kalmanfilter (Effertz, 2009) um verbesserte Konturaktualisierungen sowie einen Konturklassifikator auf Basis der Evidenztheorie erweitert. Diese Verbesserungen ermöglichen eine Reduzierung der verwendeten Stützpunkte. Ferner werden Perspektivwechsel von überholenden Fahrzeugen besser unterstützt, da diese durch den Klassifikator explizit erkannt werden.

Schlüsselwörter: Dempster-Shafer Filter, Kalmanfilter, Sensordatenfusion, Konturklassifikation

1 Einleitung

Als Nachfolge zum Projekt CarOLO der TU Braunschweig richtet sich das Projekt Stadtpilot nicht mehr an Szenarien auf abgeschlossenen Testgeländen mit durch Testfahrer simuliertem Verkehr, sondern verlagert das Szenario auf innerstädtische Straßen mit realen Verkehrsteilnehmern. Im Sommer 2010 hat der Versuchsträger bereits die ersten Testfahrten mit autonomer Längs- und Querführung auf dem Braunschweiger Stadtring erfolgreich absolviert.

*Sebastian Ohl ist wissenschaftlicher Mitarbeiter am Institut für Regelungstechnik, TU Braunschweig, Hans-Sommer-Str. 66, 38106 Braunschweig (e-mail: ohl@ifr.ing.tu-bs.de).

†Markus Maurer ist Professor am Institut für Regelungstechnik, TU Braunschweig, Hans-Sommer-Str. 66, 38106 Braunschweig (e-mail: maurer@ifr.ing.tu-bs.de).

Im neuen Testumfeld ist die Eigengeschwindigkeit gegenüber der während der Urban Challenge erreichten Geschwindigkeit von ca. 30 km/h auf bis zu 50-60 km/h bei Überholmanövern erhöht. Darüber hinaus steigt die Anzahl der Fremdfahrzeuge erheblich. Motorradverkehr und LKWs sind im Gegensatz zur Urban Challenge ebenfalls Teil des Szenarios.

Um das Fahrzeugumfeld wahrnehmen zu können, ist der eingesetzte Versuchsträger mit diversen Sensoren zur Umfeldwahrnehmung ausgestattet. Diese werden mithilfe einer objektbasierten Sensordatenfusion zu einem einheitlichen Bild der Umgebung fusioniert, um die Fahrerassistenzapplikation darstellen zu können und eine einheitliche Schnittstelle zur Umfeldwahrnehmung zur Verfügung zu stellen. Durch Verfolgung (Tracking) von bekannten Objekthypothesen mit einem Beobachter können ferner nicht durch die Sensoren gemessene Größen, wie z. B. Beschleunigungen (Bar-Shalom u. a., 2002), berechnet werden.

Die objektbasierte Sensordatenfusion des Projekts CarOLO verarbeitete Objekthypothesen, beschrieben durch offene Polygonzüge (Konturen). Diese wurden um einen Geschwindigkeitsvektor sowie dessen Ableitungen ergänzt, welche mit einem Kontur schätzenden Kalmanfilter fusioniert wurden. Der direkte Einsatz dieses Systems zeigte sich jedoch als nicht robust genug gegenüber der erhöhten Geschwindigkeit und der höheren Verkehrsdichte. So waren beispielsweise Verzerrungen der Kontur durch eine zu geringe Messfrequenz oder fehlerhafte Geschwindigkeitsvektoren zu beobachten. Um diesem entgegen zu wirken, ließe sich beispielsweise anstatt der Beschreibung durch Konturen eine starrere Umfeldmodellierung durch Boxen (Dietmayer u. a., 2005; Kämpchen, 2007) nutzen. Diese würde aber die Beschreibung der Randbebauung erheblich einschränken. Zudem würde so ein großer Teil der im Vorgängersystem vorhandenen Flexibilität verloren gehen.

Der in diesem Beitrag beschriebene Ansatz beschränkt die Flexibilität der Beschreibung der Kontur einer Objekthypothese nicht, verbessert aber das Tracking der am häufigsten vorkommenden anderen Verkehrsteilnehmer durch eine Klassifikation der Messdaten erheblich. Durch die Klassifikation in manuell festgelegte Polygonzüge wird die Beschreibung der Kontur eines Tracks durch die minimal notwendige Anzahl an Stützpunkten erreicht. Dies führt zu einem verbesserten Tracking von klassifizierten Objekthypothesen, da Verzerrungen der Kontur durch die festgelegten Formen der klassifizierten Polygonzüge nicht mehr auftreten und so keinen Einfluss auf die anderen Zustandsgrößen ausüben.

Im Vergleich zur durch Wender (2007) genutzten Klassifikation von segmentierten Lasermesspunkten werden hier nicht nur einzelne Bezugspunkte für die Aktualisierung eines Kalman Filters mit dem Box-Objekthypothesenmodell (Dietmayer u. a., 2005) bestimmt, sondern mithilfe der Klassifikation aktiv in die Beschreibungsform der Objekthypothese eingegriffen. Dies ähnelt dem Verfahren des Interacting Multiple Model Filter, wie er beispielsweise von Kämpchen (2007) genutzt wird. In dem hier beschriebenen Verfahren wird jedoch nicht das Bewegungs-, sondern das geometrische Beschreibungsmodell gewechselt.

Im Folgenden wird zunächst die genutzte Sensorkonfiguration vorgestellt, um die Eingangsdaten zu beschreiben. Der nächste Abschnitt erörtert das genutzte Objekthypothesenmodell, welches in dem anschließenden Abschnitt für die Erweiterungen der Filterstruktur genutzt wird. Ergebnisse einer Messfahrt im realen Verkehr vermitteln im letzten Abschnitt einen Eindruck von den Möglichkeiten des Filters.

2 Sensorkonfiguration

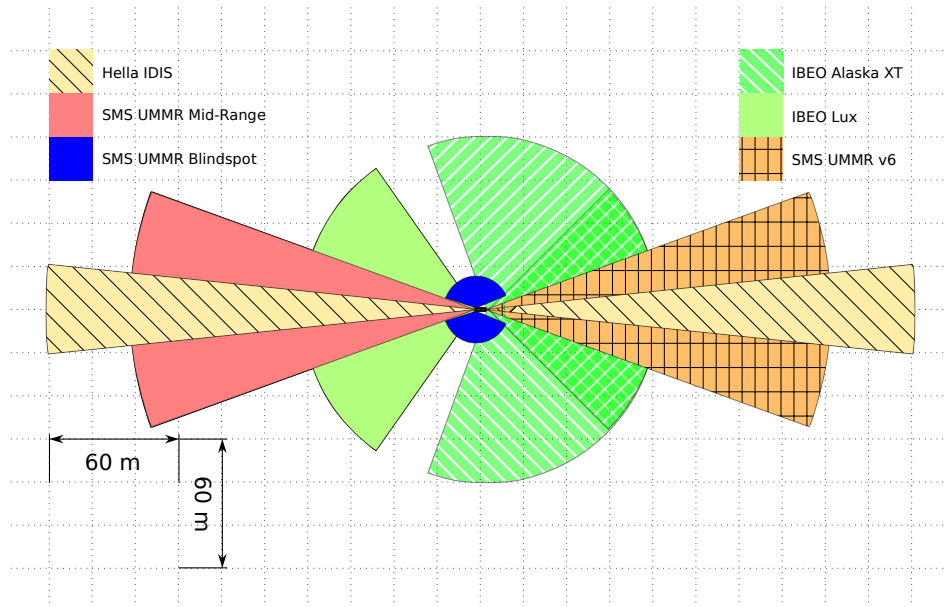


Abbildung 1: Sensorkonfiguration der objektbasierten Sensordatenfusion des Versuchsträgers Leonie im Projekt Stadtpilot

Als Versuchsträger wird im Projekt Stadtpilot "Leonie" eingesetzt, ein VW Passat Baujahr 2007. Der mit Laser- und Radarsensoren ausgerüstet wurde (siehe Abbildung 1). Diese führen bereits eine Objekthypothesenbildung durch, sodass durch den in diesem Beitrag beschriebenen Filter nur eine Fusion dieser Objektdaten durchgeführt werden muss. Im vorderen Bereich des Fahrzeugs sind zwei Laserscanner vom Typ IBEO Alaska XT, ein Lasersensor vom Typ Hella IDIS sowie ein Radarsensor des Typs SMS UMMR 2010 angebracht. Das Heck des Fahrzeugs ist mit Sensoren des Typs SMS UMMR 2006, mit einem weiteren Hella IDIS sowie einem Laserscanner vom Typ IBEO Lux ausgerüstet. Die Messdaten weiterer am Fahrzeug verbauter Sensoren, wie beispielsweise ein Laserscanner vom Typ Hella IDIS 2, werden von der objektbasierten Sensordatenfusion nicht verarbeitet.

Je nach Sensortyp wird eine unterschiedlich aufwendige Vorverarbeitung mit unterschiedlichen Beschreibungsformen der Objekthypothesen durch die Steuergeräte durchgeführt. In Tabelle 1 sind die Sensortypen den genutzten Objekthypothesenmodellen zugeordnet:

Sensor	Objekthypothesenmodell
IBEO Alaska XT	Offener Polygonzug mit Geschwindigkeitsvektor
IBEO Lux	Offener Polygonzug mit Geschwindigkeitsvektor
Hella IDIS	Strecke
SMS UMMR 2010	Punkt mit Geschwindigkeitsvektor
SMS UMMR 2006	Punkt mit radialer Geschwindigkeit

Tabelle 1: Objekthypothesenmodelle der eingesetzten Sensoren am Versuchsträger Leonie

Alle akquirierten Daten lassen sich auf einen offenen Polygonzug abbilden, sodass eine einheitliche Verarbeitung der Daten durch die Sensordatenfusion und die spätere Applikation vereinfacht wird.

3 Objekthypothesenmodell

Das Objekthypothesenmodell des Filters orientiert sich am Coordinated Turn Model (Blackman und Popoli, 1999) mit einer Winkelgeschwindigkeit von $\omega = 0$. Es ist beschrieben durch einen offenen Polygonzug $(x_0, y_0 \dots x_n, y_n)$ mit Geschwindigkeitsvektor, bestehend aus Geschwindigkeit v und Winkel der Geschwindigkeit α sowie der zugehörigen Beschleunigung a entlang des Geschwindigkeitsvektors. Im Vergleich zum Zustandsvektor der Sensordatenfusion des CarOLO Projekts wurde der hier eingesetzte um den Zustand der Winkelgeschwindigkeit ω reduziert, um den von Effertz (2008) beschriebenen Spezialfall der nicht Beobachtbarkeit bei $\omega = 0$ zu umgehen und die Komplexität der Matrixoperationen zu reduzieren. Durch die Reduzierung wird die Änderung der Ausrichtung der Objekthypothese nicht mehr geschätzt. In der Praxis hat sich hier keine substantielle Verschlechterung der anderen Zustandsgrößen gezeigt. Der Zustandsvektor \hat{x} bestimmt sich damit zu:

$$\hat{x} = [x_0 \ y_0 \ \dots \ x_n \ y_n \ \alpha \ v \ a]^T \quad (1)$$

Der Geschwindigkeitsvektor beschreibt die Verschiebung der Kontur als Ganzes. Dies entspricht nur näherungsweise der Realität, da sich durch Perspektivänderungen Teile der Kontur erweitern oder reduzieren. Allgemein hängt die Korrektheit des Geschwindigkeitsvektors somit direkt von der Komplexität und der Änderung der Kontur ab, da bei größerer Anzahl von Stützpunkten das Konturrauschen die Schätzung stark verändert.

Das Prozessmodell des Zustandsvektors $\hat{x}[k]$ zum diskreten Zeitpunkt k ergibt sich damit zu:

$$\begin{aligned} x_i[k+1] &= x_i[k] + v[k] * \cos(\alpha[k]) * \Delta t + \frac{1}{2} * a[k] * \cos(\alpha[k]) * \Delta t^2, \quad i \in [0..n] \\ y_i[k+1] &= y_i[k] + v[k] * \sin(\alpha[k]) * \Delta t + \frac{1}{2} * a[k] * \sin(\alpha[k]) * \Delta t^2, \quad i \in [0..n] \\ \alpha[k+1] &= \alpha[k] \\ v[k+1] &= v[k] + a[k] * \Delta t \\ a[k+1] &= a[k] \end{aligned} \quad (2)$$

Δt beschreibt die Prädiktionsdauer.

4 Filter

In der Filterstruktur der Sensordatenfusion des Projekts CarOLO wurden nur die Phasen eins (Zuordnung Punkt-zu-Punkt) und drei (Hinzufügen von Punkten) der Konturpunktzuordnung durchgeführt. Phase zwei (Zuordnung Punkt-zu-Strecke) sowie die Klassifikation der Eingangsdaten stellen die Erweiterungen gegenüber dem von Effertz (2009) beschriebenen Filter da. Die Filterstruktur wird in Abbildung 2 dargestellt.

Das Prozessmodell des Extended Kalmanfilters stellt hier, wie in Abschnitt 3 beschrieben, nur die Bewegung im Objektschwerpunkt ab und reduziert so die Komplexität erheblich gegenüber einem Bewegungsmodell, in dem jeder Konturpunkt einzeln geschätzt würde, da sie nicht mehr von der Anzahl der Konturpunkte des Zustandsvektors abhängt.

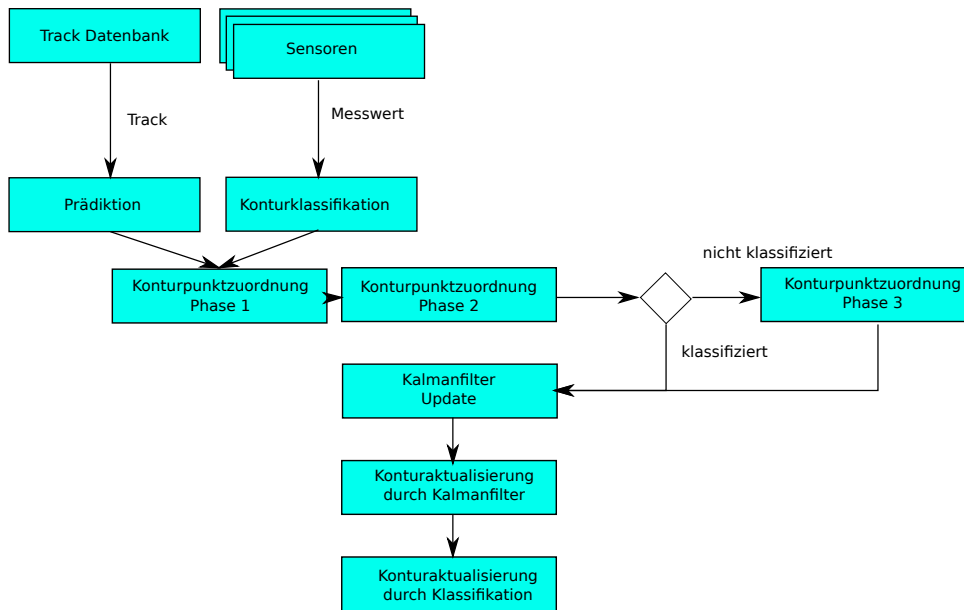


Abbildung 2: Struktur des Filters

Nach einer Zuordnung der Messwerte zu bekannten Objekthypothesen (Tracks) werden zunächst die Messwerte bezüglich ihrer Kontur klassifiziert (siehe Abschnitt 4.3). Parallel dazu wird der Track entsprechend des Prozessmodells prädiziert. Anschließend erfolgt die Zuordnung von Konturstützpunkten des Messwerts zu denen des Tracks durch die Ausführung der ersten beiden Phasen der Konturpunktzuordnung. Für nicht klassifizierbare Messwerte folgt eine dritte Phase, in der neue Punkte erzeugt werden können. Eine detaillierte Beschreibung findet sich in Abschnitt 4.1. Die während der Zuordnung gewonnenen durchschnittlichen Abweichungen ($\Delta\bar{x}$, $\Delta\bar{y}$) zwischen dem Track und dem Messwert bilden den Eingang für den Aktualisierungsschritt des Extended Kalmanfilters.

Nach der Aktualisierung des Zustandsvektors durch das Extended Kalmanfilter schließt sich die Aktualisierung der Kontur des Tracks an (siehe Abschnitt 4.2). Durch den Filterschritt wurden die Verschiebungen der Konturpunkte seit dem letzten Zeitschritt bestimmt. Diese werden nun auf die bestehenden Konturpunkte aufaddiert und Punkte, die über einen gewissen Zeitraum nicht aktualisiert wurden, aus der Kontur entfernt.

Der letzte Schritt der Filterstruktur stellt eine Ersetzung der Kontur bei einer geänderten Klassifikation dar. Ist ein Messdatum erfolgreich klassifiziert worden und hat sich diese Klassifikation gegenüber dem letzten Zeitschritt verändert, so wird die erkannte Kontur an Größe und Lage im Raum des Messwerts angepasst und anstelle der bestehenden Kontur des Tracks eingesetzt.

4.1 Konturpunktzuordnung

Da das Extended Kalmanfilter nicht jeden Punkt einzeln behandelt, sondern nur ein auf den Schwerpunkt reduziertes Prozessmodell enthält, ist eine Zuordnung von Punkten der Messkontur zur Kontur des Tracks notwendig. Diese Zuordnung ist in drei Phasen aufgeteilt:

1. Punkt-zu-Punkt-Zuordnung
2. Punkt-zu-Strecke-Zuordnung
3. Hinzufügen neuer Punkte




Abbildung 3: Konturpunktzuordnung Phase 1

Die erste Phase beschreibt das bereits von Effertz (2009) eingesetzte Verfahren. Hierbei werden 1-zu-1 Zuordnungen zwischen den Stützpunkten der Kontur der Messung und der Kontur des Tracks durchgeführt (siehe Abbildung 3). Ein Gating-Verfahren mit dem euklidischen Abstand als Metrik verhindert (Becker, 2002), dass Zuordnungen über große Distanzen stattfinden. Nach erfolgreicher Zuordnung wird die Verschiebung zwischen den Punkten bestimmt.




Abbildung 4: Konturpunktzuordnung Phase 2

Die zweite Phase widmet sich den Punkten, die in Phase 1 nicht zugeordnet werden konnten. Sie führt eine Zuordnung zwischen einem Punkt der Messkontur und der Strecke zwischen zwei Stützpunkten der Trackkontur durch (siehe Abbildung 4). Dies ermöglicht es beispielsweise, die von einem zweiten Sensor gemessenen Punkte zur Aktualisierung zu nutzen, ohne einen weiteren Stützpunkt auf einer Gerade einfügen zu müssen. Der Abstand des Punktes zur Strecke trägt zum Messvektor des Extended Kalmanfilters bei.

Punkte, die in den ersten Phasen nicht zugeordnet wurden, werden in Phase 3 der Kontur neu hinzugefügt. Sie tragen zur Aktualisierung des Extended Kalmanfilters in diesem Zeitschritt nichts bei. Die dritte Phase wird ferner nur bei unklassifizierten Tracks angewendet. Für andere Tracks ist über die Klassifikation eine spezielle Anzahl Konturpunkte festgeschrieben (siehe Abschnitt 4.3).

4.2 Extended Kalmanfilter

Der in Formel 1 beschriebene Zustandsvektor wird für den Extended Kalmanfilter auf die Verschiebung seines Bewegungsschwerpunkts reduziert. So wird die Komplexität erheblich

reduziert, da der Zustandsvektor eine feste Dimension besitzt und nicht weiter von der Anzahl der Konturpunkte abhängt. Der vereinfachte Zustandsvektor ergibt sich damit zu:

$$x = [\Delta x \quad \Delta y \quad \alpha \quad v \quad a]^T \quad (3)$$

Das Prozessmodell entspricht dem bereits vorgestellten mit $x[k] = 0, y[k] = 0$. Die während der Zuordnung gewonnenen Abweichungen $(\Delta x_i, \Delta y_i)$ zwischen dem Track und dem Messwert bilden den Messvektor z_k des Extended Kalmanfilters. Je nach Eingangsdaten (siehe Tabelle 1) wird dieser Messvektor noch um einen Geschwindigkeitsvektor ergänzt, sodass sich z_k zu Folgendem ergibt:

$$z_k^{Position} = [\frac{1}{N} \sum_{i=1}^N \Delta x_i \quad \frac{1}{N} \sum_{i=1}^N \Delta y_i]^T \quad (4)$$

$$z_k^{Position/Geschwindigkeit} = [\frac{1}{N} \sum_{i=1}^N \Delta x_i \quad \frac{1}{N} \sum_{i=1}^N \Delta y_i \quad \alpha \quad v]^T \quad (5)$$

Die Zahl N ist die Anzahl der während der Phasen 1 und 2 getroffenen Zuordnungen. Die Jacobimatrix H der Beobachtungsmatrix h ergibt sich somit zu einer Einheitsmatrix der entsprechenden Dimension von y .

Nach Aufstellung des Messvektors und der Beobachtungsmatrix lässt sich der Aktualisierungsschritt des Extended Kalmanfilters durchführen.

$$\tilde{y}_k = z_k - H_k * \hat{x}_{k|k-1} \quad (6)$$

$$S_k = H_k * P_{k|k-1} * H_k^T + R_k \quad (7)$$

$$K_k = P_{k|k-1} * H_k^T S_k^{-1} \quad (8)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k * \tilde{y}_k \quad (9)$$

$$P_{k|k} = (I - K_k * H_k) * P_{k|k-1} \quad (10)$$

Die Kalmanverstärkung K_k wird für alle Konturpunkte nur einmal berechnet und für alle Stützpunkte als gleich angenommen. Die Aktualisierung eines einzelnen Punkts mit Messwertzuordnung ergibt sich damit zu:

$$x_{i,k|k} = x_{i,k|k-1} + K_k * \Delta x_{i,k} \quad (11)$$

$$y_{i,k|k} = y_{i,k|k-1} + K_k * \Delta y_{i,k} \quad (12)$$

Nicht zugeordnete Stützpunkte erfahren eine Aktualisierung basierend auf den Werten von $\hat{x}_{k+1|k+1}\{1, 2\}$.

4.3 Konturklassifikator

Der Konturklassifikator bildet den Kern der Erweiterung des Fusionssystems aus dem Projekt CarOLO. Es schätzt die Kontur der Messwerte und ersetzt bei erfolgreicher Klassifikation die Kontur des Tracks, um eine vereinfachte Darstellung und damit einen geringeren Rechenaufwand und ein verbessertes Tracking zu erreichen.

Zur Klassifikation wurden Konturen ausgewählt, die häufig im Testgebiet eines innerstädtischen Rings auftreten und selbst auf ihre Bewegung Einfluss nehmen können. Bedingt durch die von den Sensoren erstellten Objekthypothesen wird nach folgenden Konturen klassifiziert:

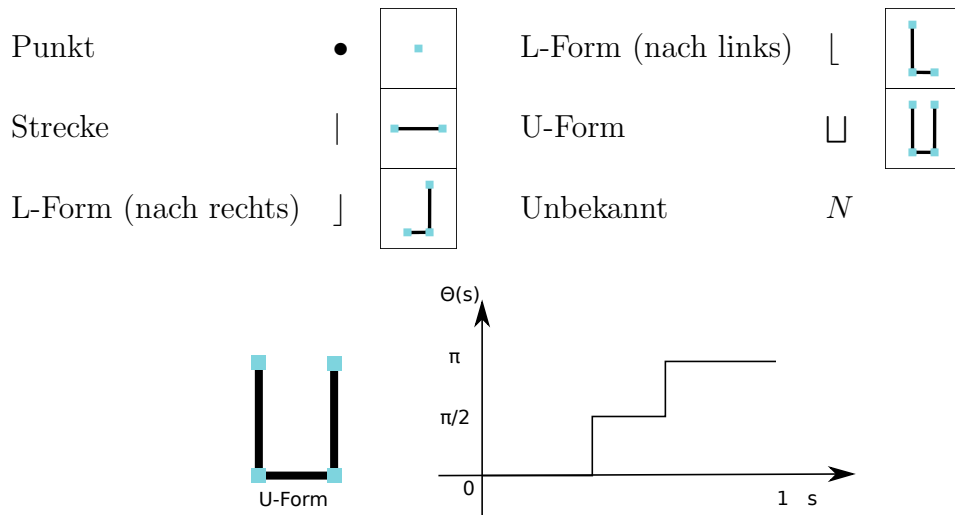


Abbildung 5: Turningfunktion einer U-Form

Mithilfe des von Arkin u. a. (1990) beschriebenen Algorithmus lassen sich Konturen durch Normierung unabhängig von Ausdehnung, Rotation und Position vergleichen. Hierbei wird auf die Turningfunktion $\Theta_A(s)$ zurückgegriffen. Sie misst den Winkel zwischen den Schenkeln zweier Strecken eines Polygonzugs A entgegen dem Uhrzeigersinn als Funktion über der Länge des Polygonzuges. Durch eine Normierung des Polygonzuges auf der Länge s auf den Wert 1 wird die Ausdehnungsunabhängigkeit erreicht. Abbildung 5 zeigt die Turningfunktion einer U-Form. Wird für zwei Polygonzüge A und B diese Funktion berechnet und schließlich das Integral der Differenz gebildet, so erhält man einen Ähnlichkeitswert für die Polygonzüge:

$$D_B^A = \int_0^1 |\Theta_A(s) - \Theta_B(s)| ds \tag{13}$$

Die Fusion der durch die Klassifikation gewonnenen Ähnlichkeitswerte mit den Werten des Tracks wird mithilfe eines Dempster-Shafer-Filter (Wu u. a., 2002) (D-S) durchgeführt. Hierzu wird ein Wahrscheinlichkeits-Potenzraum mit den Elementen der zu klassifizierenden Konturen zuzüglich der nicht klassifizierbaren Kontur N aufgestellt:

$$2_{Polyline}^\Theta = \{N, \bullet, |,], [, \sqcup\} \tag{14}$$

Die zugehörige Massenverteilung des D-S

$$\begin{aligned} M(N) &\in [0, 1] & M(]) &\in [0, 1] \\ M(\bullet) &\in [0, 1] & M(|) &\in [0, 1] \\ M(|) &\in [0, 1] & M(\sqcup) &\in [0, 1] \end{aligned}$$

$$M(N) + M(\bullet) + M(|) + M(]) + M(\sqcup) = 1$$

ergibt sich aus dem Potenzraum und wird dem Zustandsvektor eines jeden Tracks hinzugefügt. Mithilfe der durch den Klassifikator bestimmten Ähnlichkeitswerte D_B^A lässt sich ebenfalls eine Massenverteilung durch Normierung der Werte auf 1 erstellen. Durch die

D-S-Kombinationsregel können die Massen des Tracks M_A und des Klassifikators M_B zu einer neuen Massenverteilung M_C zusammengeführt werden:

$$M_C = M(C|A, B) = \frac{1}{1 - \kappa} \sum_{i,j|A_i \cap B_j = C} M_A(A_i) * M_B(B_j) \quad (15)$$

$$\kappa = \sum_{i,j|A_i \cap B_j = \emptyset} M_A(A_i) * M_B(B_j) \quad (16)$$

Nach der Kombination kann aus den neu bestimmten Massen die Kontur mit der größten Evidenz gefunden werden.

Zur Bestimmung der Ähnlichkeitswerte muss ein Polygonzug zumindest drei Stützpunkte aufweisen. Somit ist die Bestimmung der Massen des Potenzraums nicht für alle Eingangsdaten möglich. Für die Objekthypothesen, welche durch ein Objekthypothesenmodell beschrieben werden, das nur Punkte oder Strecken darstellen kann, müssen zusätzlich andere Potenzräume aufgestellt werden:

$$2_{Punkt}^{\ominus} = \{N, (\bullet, |,], \lfloor, \sqcup)\} \quad (17)$$

$$2_{Strecke}^{\ominus} = \{N, \bullet, (|,], \lfloor, \sqcup)\} \quad (18)$$

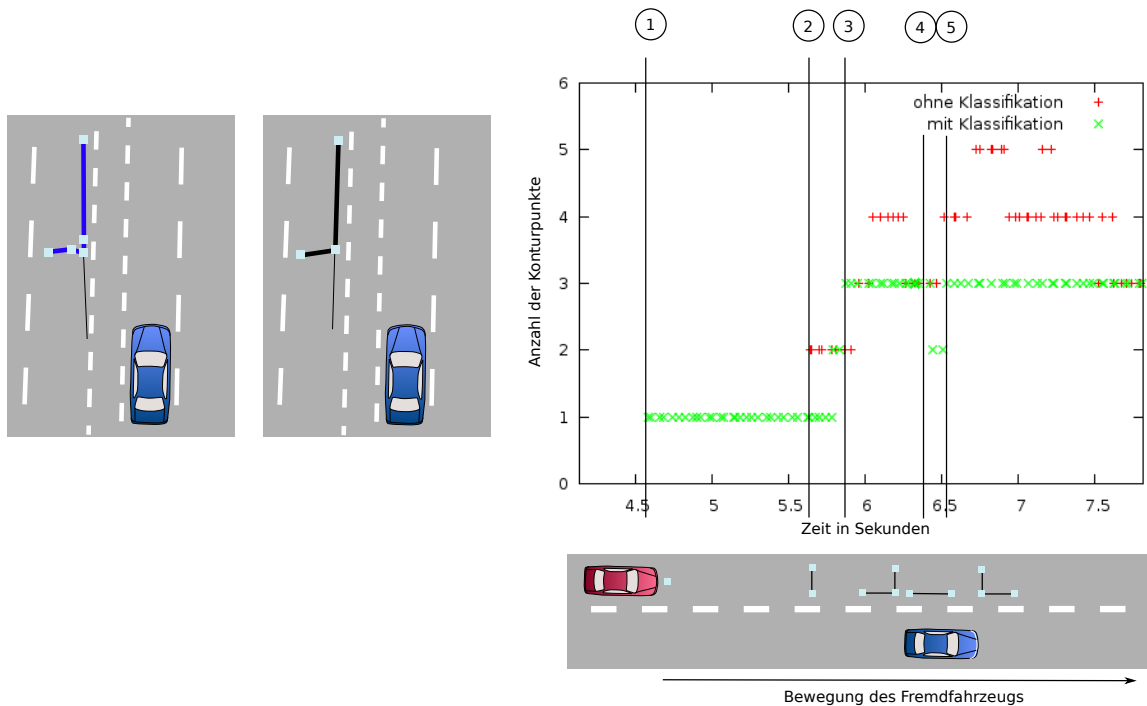
Hierbei werden die nicht durch das Objekthypothesenmodell beschreibbaren Massen zu einer Menge zusammengefasst, da durch eine Objekthypothese mit Punktobjekthypothesenmodell in der Realität beispielsweise eine U-Form abgebildet werden kann. Gleiches gilt für Objekthypothesen mit Streckenobjekthypothesenmodell. Ist die Strecke sehr kurz und kann damit als Punkt betrachtet werden, so lässt sich die Masse Punkt entsprechend stützen. Ab einer gewissen Breite ist aber nicht sicher, ob die dargestellte Strecke nicht Teil einer anderen komplexeren Kontur ist und lediglich nicht vollständig durch den Sensor abgebildet werden kann.

Bei jeder Änderung der Konturschätzung wird die Kontur des Tracks nach der Aktualisierung durch das Extended Kalmanfilter durch die geschätzte Kontur ersetzt. Hierzu wird diese skaliert und mithilfe des Konturklassifikators ein optimaler Winkel im Raum bestimmt. In der bisher eingesetzten Form war der Klassifikator drehinvariant. Wird jedoch eine virtuelle Strecke ortsfest zum ersten Punkt des Polygonzugs A des Klassifikators definiert (A') und die Funktion $\Theta_{A'}(s)$ neu bestimmt, so führt dies zu einer Verschiebung auf der Y-Achse. Auf diese Weise kann durch Durchlaufen des Drehbereiches $[-\pi, \pi)$ der optimale Winkel mit dem geringsten Fehler durch Minimierung des Integrals $D_B^{A'}$ bestimmt werden.

In der weiteren Verarbeitung wird die Kontur nur noch über die Phasen 1 und 2 der Konturzuordnung behandelt, um keine neuen Punkte hinzuzufügen, da die grundsätzliche Form der Kontur durch die Klassifikation vorgegeben ist. Eventuelle Unähnlichkeiten, wie beispielsweise eine geringe Verzerrung einer L-Form, können durch die Phase 1 durch die direkte Zuordnung der Stützpunkte ausgeglichen werden.

5 Ergebnisse

Abbildung 6(a) zeigt eine Fahrsituation auf dem Braunschweiger Stadtring, die während einer Messfahrt aufgenommen wurde. Der Versuchsträger Leonie fährt auf der linken Spur



(a) Vergleich von Messdatum mit klassifiziertem Ergebnis. Messdatum des IBEO Alaska XT (links), Track (rechts)

(b) Anzahl der Konturpunkte über der Zeit

Abbildung 6: Messergebnisse

der rechten Fahrbahn und ein Fremdfahrzeug kommt ihm auf der Gegenseite entgegen. Die Kontur des anderen Fahrzeugs beschreibt der Sensor mit fünf Punkten. Der D-S-Filter hat dieses Datum als "L-Form (links)" klassifiziert und die Kontur entsprechend ersetzt. Die leichte Öffnung der L-Form kommt durch die erste Phase der Konturpunktzuordnung zustande. Die geringere Punktzahl der Kontur macht den Track weniger anfällig gegenüber Rauschteilen. Hierdurch verbessert sich beispielsweise die Schätzung des Geschwindigkeitsvektors. Zu sehen ist, dass der Vektor des Tracks sich exakt entlang der Fahrbahn des Luftbilds bewegt, während der Vektor des Messwerts um $\approx 4^\circ$ abweicht.

In Abbildung 6(b) ist die Anzahl der Konturpunkte mit und ohne Klassifikation eines überholenden Fahrzeugs über der Zeit aufgetragen. Während das Tracking mit Klassifikation bereits ab 4.5s das Ziel stabil erfasst hat (Markierung 1), findet ohne Klassifikation bei 5.6s ein Abriss des Trackings statt (Markierung 2) und ein neuer Track muss initialisiert werden. Dargestellt wird hier nur der neue Track. Vergleicht man die Anzahl der Konturpunkte mit und ohne Klassifikation, wird die Reduktion der Punkte deutlich. Zu sehen sind die Wechsel der Konturen des Ziels. Zunächst wird es durch einen Punkt dargestellt (Markierung 1), wandelt sich anschließend in eine durch zwei Punkte beschriebene Strecke (Markierung 2) und schließlich zu einer durch drei Punkte beschriebenen L-Form um (Markierung 3). Während beide Fahrzeuge auf einer Höhe sind (ca. 6.5s), wird es erneut kurz durch eine Strecke dargestellt (Markierung 4), um schließlich wieder zu einer L-Form zu werden (Markierung 5). Ohne die Klassifikation wird die Kontur meist durch vier oder kurzzeitig sogar durch fünf Punkte abgebildet.

6 Zusammenfassung und Ausblick

In diesem Beitrag wurde ein Kontur schätzendes Kalmanfilter für ein urbanes Umfeld vorgestellt. Dieses klassifiziert die Messdaten zunächst auf Basis der Turningfunktion und fusioniert das Ergebnis mithilfe eines D-S-Filters. Bei geänderter Klassifikation wird nach der Aktualisierung des Zustandsvektors durch den Extended Kalmanfilter die Kontur des Tracks durch die klassifizierte ersetzt. Dies führt zu einer erheblich verbesserten Beschreibung von häufig auftretenden Konturen bei gleichzeitiger Erhaltung der Flexibilität des Frei-Form-Kontur-Objekthypothesenmodells für unklassifizierte Objekthypothesen.

Das beschriebene Verfahren wird zur Zeit im Projekt Stadtpilot für autonome Fahrten im innerstädtischen Gebiet eingesetzt und weiterentwickelt. Möglich wäre beispielsweise, Teilkonturen zu klassifizieren, um durch Aneinanderreihung von Elementarkonturen auch komplexere Strukturen effektiv beschreiben zu können oder die Klassifikationen der Sensoren mit einzubeziehen. Außerdem lässt sich die Ersetzung von Konturen durch die klassifizierte Grundform hinsichtlich der Schätzung der optimalen Rotation und Skalierung verbessern, um eine durchgängig bessere Schätzung der Zustandsgrößen zu ermöglichen. Zur objektiven Bewertung des Verfahrens ist geplant, eine Implementierung des Interacting Multiple Model Filters mit unterschiedlichen geometrischen Objekthypothesenmodellen durchzuführen.

Literatur

- [Arkin u. a. 1990] ARKIN, Esther M. ; CHEW, L. P. ; HUTTENLOCHER, David P. ; KEDDEM, Klara ; MITCHELL, Joseph S. B.: An efficiently computable metric for comparing polygonal shapes. In: *SODA '90: Proceedings of the first annual ACM-SIAM symposium on Discrete algorithms*. Philadelphia, PA, USA : Society for Industrial and Applied Mathematics, 1990, S. 129–137
- [Bar-Shalom u. a. 2002] BAR-SHALOM, Yaakov ; KIRUBARAJAN, Thiagalingam ; LI, X.-Rong: *Estimation with Applications to Tracking and Navigation*. New York, NY, USA : John Wiley & Sons, Inc., 2002. – ISBN 0471221279
- [Becker 2002] BECKER, Jan-Carsten: *Fusion der Daten der objekterkennenden Sensoren eines autonomen Straßenfahrzeugs*, Institut für Regelungstechnik, Technische Universität Braunschweig, Dissertation, März 2002
- [Blackman und Popoli 1999] BLACKMAN, S. ; POPOLI, R.: *Design and Analysis of Modern Tracking Systems*. Norwood : Artech House Publishers, 1999
- [Dietmayer u. a. 2005] DIETMAYER, Klaus ; KIRCHNER, Alexander ; KÄMPCHEN, Nico: Fusionsarchitekturen zur Umfeldwahrnehmung für zukünftige Fahrerassistenzsysteme. In: *Fahrerassistenzsysteme mit maschineller Wahrnehmung*. Markus Maurer und Christoph Stiller (Hrsg.), 2005, S. 59–88
- [Effertz 2008] EFFERTZ, Jan: Hybride Sensorfusion zur Fahrzeug-Umfeldererkennung und Fahrbereichsanalyse. In: *5. Workshop Fahrerassistenzsysteme*. Walting, April 2008, S. 76–85

- [Effertz 2009] EFFERTZ, Jan: *Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle*, Institut für Regelungstechnik, Technische Universität Braunschweig, Dissertation, Februar 2009
- [Kämpchen 2007] KÄMPCHEN, Nico: *Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems*, Universität Ulm, Dissertation, 2007
- [Ohl 2007] OHL, Sebastian: *Entwicklung einer Multi-Sensor-Datenfusion für ein autonomes Straßenfahrzeug*. Institut für Regelungstechnik, Technische Universität Braunschweig, Diplomarbeit, Juli 2007
- [Rauskolb u. a. 2008] RAUSKOLB, Fred W. ; BERGER, Kai ; LIPSKI, Christian ; MAGNOR, Marcus ; CORNELSEN, Karsten ; EFFERTZ, Jan ; FORM, Thomas ; GRAEFE, Fabian ; OHL, Sebastian ; SCHUMACHER, Walter ; WILLE, Jörn-Marten ; HECKER, Peter ; NOTHDURFT, Tobias ; DOERING, Michael ; HOMEIER, Kai ; MORGENROTH, Johannes ; WOLF, Lars ; BASARKE, Christian ; BERGER, Christian ; GÜLKE, Tim ; KLOSE, Felix ; RUMPE, Bernhard: Caroline: An autonomously driving vehicle for urban environments. In: *Journal of Field Robotics* 25 (2008), August, Nr. 9, S. 674–724
- [Wender 2007] WENDER, Stefan: *Multisensorsystem zur erweiterten Fahrzeußerfassung*, Universität Ulm, Dissertation, 2007
- [Wille u. a. 2009] WILLE, J. ; MATTHAEI, R. ; OHL, S. ; SAUST, F. ; MAURER, M. ; SCHUMACHER, W. ; HOMEIER, K ; NOTHDURFT, T. ; SASSE, A. ; HECKER, P. ; WOLF, L.: Der Stadtpilot - Autonomes Fahren auf dem Braunschweiger Stadtring. In: *AAET 2009, Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel* Gesamtzentrum für Verkehr Braunschweig e.V. (Veranst.), 2009, S. 27–47
- [Wu u. a. 2002] WU, H. ; SIEGEL, M. ; STIEFELHANGEN, R ; YANG, J.: Sensor Fusion Using Dempster-Shafer Theory. In: *IEEE International Measurement Technology Conference*. Anchorage AK, USA, 2002