

Fahrstreifengenaue Kreuzungsschätzung anhand der Fahrtverläufe anderer Verkehrsteilnehmer

Annika Meyer*, Jonas Walter*, Martin Lauer† und Christoph Stiller†

Zusammenfassung: In diesem Beitrag wird ein Markov-Chain-Monte-Carlo-Ansatz vorgestellt, der ohne Kartenvorwissen sowohl das geometrische Layout einer Kreuzung als auch den genauen Verlauf der Fahrstreifen aus den Fahrtverläufen anderer Verkehrsteilnehmer schätzt. Das Modell ist flexibel gestaltet und nicht auf eine bestimmte Anzahl Arme oder Fahrstreifen beschränkt. Das Verfahren ist so konzipiert, dass laufend neue Messungen aufgenommen und genauso kontinuierlich Schätzungen abgegeben werden können. Der Ansatz wird auf 1 000 simulierten und 14 realen Kreuzungen evaluiert. Das Layout der Kreuzung kann dabei in unter 30 ms in mehr als 99 % der Fälle richtig geschätzt werden. Auf dieser Basis erreicht die Fahrstreifenschätzung in 100 ms einen Fehler von nur 14 cm. Nach den genannten Zeiten verbessert sich die Schätzung kontinuierlich durch Aufnahme neuer Messungen und Analyse weiterer Hypothesen.

Schlüsselwörter: Fahrstreifen, Kreuzungen, Kartenloses Fahren, Markov-Chain-Monte-Carlo

1 Einleitung

Heutige Systeme für automatisiertes Fahren verlassen sich größtenteils auf die Korrektheit einer hochgenauen Karte, um eine valide Verhaltensplanung zu ermöglichen. Hochgenaue Karten können dabei Wahrnehmungsaufgaben wie bspw. die Schätzung von Fahrstreifenrändern vereinfachen oder ersetzen. Durch Baustellen oder Verkehrsunfälle können sich diese Informationen jedoch ändern, sodass eine Karte veraltet. Der Aufwand, hochgenaue Karten aktuell zu halten, kann so schnell explodieren. Zusätzlich benötigen hochgenaue Karten eine hochpräzise Lokalisierung, um die gespeicherten Informationen adäquat nutzen zu können.

Bisherige Ansätze, die sich mit diesem Problem auseinandersetzen, konzentrieren sich primär auf die Fahrstreifenerkennung auf einfachen Straßen und Autobahnen [1, 2]. Wie viele andere betrachten Hou et al. [1] das Problem als eine pixelweise Segmentierung, wohingegen Homyounfar et al. [2] eine Polygon-Repräsentation wählen. Teilweise wird auch die Erkennung bzw. die Repräsentation eines Fahrstreifens übersprungen und direkt ein fahrbarer Pfad geschätzt [3, 4]. Dies hat den Vorteil, dass dynamische Objekte bereits beachtet werden, was bei einer reinen Fahrstreifenschätzung nicht der Fall ist. Eine Prädiktion anderer Verkehrsteilnehmer und damit die genaue Verhaltensplanung auf Basis dieser generierten Pfade ist jedoch schwieriger, da das Straßenlayout nicht vollständig vorliegt oder hier wiederum auf eine Karte zurückgegriffen werden muss.

*FZI Forschungszentrum Informatik, Karlsruhe (e-mail: ameyer@fzi.de)

†Institut für Mess- und Regelungstechnik, Karlsruhe Institut für Technologie (KIT), Karlsruhe

Kreuzungen sind im Vergleich zu einfachen Fahrstreifen komplexe Strukturen und wurden in bisherigen Arbeiten auf der Fahrstreifenebene kaum untersucht oder es wurden lediglich zeitaufwändige Ansätze vorgestellt.

Bestehende Ansätze befassen sich zum Beispiel mit dem Schätzen eines Verbindungsgraphen [5] oder der nicht-fahrstreifengenauen Geometrie. Geiger et al. [6] schränkt dabei das Modell der Kreuzung derartig ein, dass es kaum auf reale Kreuzungen generalisieren kann, da nur ein Fahrstreifen pro Fahrtrichtung modelliert wird. Ein geometrisch sehr flexibles Modell wird hingegen sowohl von Homayounfar et al. [2] als auch Liang et al. [7] vorgestellt, die die Ränder einer Kreuzung bzw. die Ränder von Autobahnfahrstreifen mit einem neuronalen Netz als Polygone präzisieren. Beide Ansätze können jedoch nicht die Fahrstreifen einer Kreuzung schätzen.

Andere Ansätze sind explizit für die Kartengenerierung entworfen und entsprechend zeitaufwändig. Roeth et al. [8] präsentieren dabei einen Ansatz, der aus Flottendaten Kreuzungs- und Fahrstreifengeometrien extrahiert. Die Modelle sind jedoch derartig konzipiert, dass eine Berechnung in Echtzeit nicht möglich ist. Die vorliegende Arbeit hingegen hat zum Ziel, einen echtzeitfähigen Ansatz vorzustellen, sodass einfachere Modelle notwendig sind.

Wie einige andere Arbeiten in diesem Bereich [5, 6, 8] basiert die Schätzung hier auf den Fahrtverläufen anderer Verkehrsteilnehmer, die mit verschiedenen Sensoren gemessen werden können. Um mit der kombinatorischen Komplexität aller Kreuzungshypothesen umgehen zu können, wird das Markov-Chain-Monte-Carlo (MCMC) Verfahren verwendet, bei dem verschiedene Hypothesen untersucht und die beste Hypothese ermittelt werden kann. Ein Vorteil von MCMC ist die Möglichkeit, jederzeit Zwischenergebnisse bereitzustellen zu können. Die Besonderheiten dieser Arbeit sind dabei (i) eine fahrstreifengenaue Kreuzungsschätzung auf Basis des Fahrverhaltens anderer Fahrzeuge, (ii) progressive Aufnahme neuer Messungen und (iii) eine fortwährende und damit echtzeitfähige Schätzung.

2 Markov-Chain-Monte-Carlo-Ansatz

Um das optimale Kreuzungsmodell \hat{I} gegeben der gemessenen Fahrtverläufe Z zu schätzen, wenden wir ein Maximum-A-Posteriori-Verfahren an und erhalten

$$\begin{aligned}
 P(\hat{I}|Z) &= \arg \max_I P(I|Z) \\
 &= \arg \max_I P(Z|I)P(I) \\
 &= \arg \max_I \prod_i^{ |Z| } P(z_i|I)P(I).
 \end{aligned} \tag{1}$$

Da das Modell hochdimensional ist und für die Verteilungen keine analytische Lösung existiert, kann nicht ohne Weiteres eine Wahrscheinlichkeit für jedes Modell berechnet werden. Gleichermäßen ist durch die Anzahl kombinatorischer Möglichkeiten der Parameter der Kreuzungen eine Betrachtung aller Hypothesen sowie eine geschlossene Berechnung der Wahrscheinlichkeit nicht in begrenzter Zeit möglich. Daher eignet sich ein Monte-Carlo-Ansatz, der zufallsbasiert Hypothesen zur Untersuchung aus einer Markov-Kette zieht, das Markov-Chain-Monte-Carlo-Verfahren [9].

Die Hypothesen können dabei von einer Markov-Kette generiert werden, deren Verteilung $q(x)$ proportional zu der tatsächlichen Verteilung $p(x)$ ist. Für die generierten Hypothesen kann dann geprüft werden, ob sie der Zielverteilung entsprechen, indem die A-Posteriori-Wahrscheinlichkeit auf Basis der Messungen Z berechnet wird. Eine Hypothese I' wird somit als valides Sample aus der Verteilung $p(x)$ akzeptiert, wenn sie im Bezug zum Vorgänger I die Akzeptanzbedingung

$$u \leq A(I', I) = \frac{P(I'|Z)q(I'|I)}{P(I|Z)q(I|I')} \quad (2)$$

erfüllt. u wird dabei aus einer Gleichverteilung $u \leftarrow \mathcal{U}[0, 1]$ gezogen und neue Hypothesen durch Änderungen eines einzelnen Parameters generiert. Da wir in dieser Arbeit symmetrische Verteilungen annehmen und Abweichungen davon vernachlässigen (Metropolis-Algorithmus [10]), kann auf die Berechnung $q(I'|I)$ verzichtet werden, sodass

$$\begin{aligned} u \leq A(I', I) &= \frac{P(I'|Z)}{P(I|Z)} \\ &= \frac{P(I') \prod_i^{|Z|} P(z_i|I')}{P(I) \prod_i^{|Z|} P(z_i|I)}. \end{aligned} \quad (3)$$

Durch den Einsatz eines Simulated Annealing Parameters T_s konvergieren die akzeptierten Hypothesen in ein optimales Kreuzungsmodell \hat{I} . Die Akzeptanzbedingung wird somit

$$u \leq A(I', I) = \left(\frac{P(I') \prod_i^{|Z|} P(z_i|I')}{P(I) \prod_i^{|Z|} P(z_i|I)} \right)^{\frac{1}{T_s}}. \quad (4)$$

3 Kreuzungsschätzung




Abbildung 1: Zunächst werden die Parameter (a, Grobgeschätzung) und darauf aufbauend der genaue Fahrstreifenverlauf (b, Fahrstreifen-schätzung) einer Kreuzung geschätzt.

Die Kreuzungsschätzung ist in zwei separate Schritte aufgeteilt. Im ersten Schritt werden nur die Parameter der Kreuzung geschätzt. Anschließend wird auf Basis dieser

Schätzung der eigentliche Fahrstreifenverlauf berechnet. In der Grobschätzung gehen wir zunächst davon aus, dass die Kreuzungsarme keine Krümmung aufweisen. In der Fahrstreifenschätzung wird diese Annahme dann verworfen und der tatsächliche, möglicherweise gekrümmte Verlauf bestimmt.

Für die Schätzung verwenden wir die Fahrtverläufe anderer Verkehrsteilnehmer Z , sodass jede Messung z aus der Position eines Objekts \mathbf{x} und dem Aufnahmezeitpunkt t besteht. Aus diesen Daten kann mit einer Objektverfolgung für jede Messung zusätzlich der Geschwindigkeitsvektor \mathbf{v} berechnet werden.

3.1 Grobschätzung

Für die Grobschätzung wird zunächst nur eine grobe Schätzung benötigt, sodass die Berechnung deutlich beschleunigt werden kann, indem nur zwei repräsentative Punkte $\bar{z} = (\bar{\mathbf{x}}, \bar{\mathbf{v}})$ je Fahrtverlauf für die Schätzung verwendet werden. Dazu werden alle Trajektorien am Punkt der größten Krümmung in einen Teil vor und einen Teil nach der Kreuzung aufgeteilt und jeder dieser Teile auf einen Mittelpunkt $\bar{\mathbf{x}}$ und einen mittleren Geschwindigkeitsvektor $\bar{\mathbf{v}}$ reduziert.

Wie in Abbildung 1a veranschaulicht, besteht die Kreuzung $I = (c, A)$ aus einem orientierten Zentrumspunkt c , um den wiederum eine Menge A aus Armen orientiert ist. Ein Arm wird dabei als $a = (\alpha_a, g_a, L_a^i, L_a^o, w_a)$ modelliert und besteht dabei aus der Richtung α_a eines Arms, der Breite der Lücke g_a zwischen den Fahrtrichtungen sowie der Anzahl Fahrstreifen, die in die Kreuzung hinein (L_a^i) bzw. aus ihr heraus (L_a^o) führen. Die einheitliche Breite der Fahrstreifen wird mit w_a bezeichnet.

In jedem Schritt des MCMC wird nur ein Parameter modifiziert (siehe Algorithmus 1). Über die Akzeptanzbedingung aus Gleichung 4 wird ermittelt, ob die neue Hypothese einem Sample aus der tatsächlichen Verteilung entspricht und somit sinnvoll für die weitere Hypothesengenerierung ist.

Algorithmus 1 Neue Kreuzungshypothesen werden durch Änderung jeweils eines Parameters erzeugt.

```

 $\omega \leftarrow \mathcal{U}[0, 1]$ 
if  $\omega < 0.08$  then
    rotiere Arm um  $\Delta\alpha \leftarrow \mathcal{U}[-6^\circ; 6^\circ]$ 
else if  $\omega < 0.6$  then
    verschiebe Zentrum um  $\{\Delta c; \phi\} \leftarrow \mathcal{U}([0 \text{ m}; 6 \text{ m}] \times [0; 2\pi])$ 
else if  $\omega < 0.7$  then
    ändere den Abstand der Fahrstreifen um  $\Delta g \leftarrow \mathcal{U}[-1,8 \text{ m}; 1,8 \text{ m}]$ 
else if  $\omega < 0.85$  then
    füge Arm hinzu / entferne Arm  $a \leftarrow \mathcal{U}_D(A)$ 
else
    füge Fahrstreifen hinzu / entferne Fahrstreifen  $l \leftarrow \mathcal{U}_D(L)$ 
end if

```

Für den Vergleich zweier Kreuzungen auf Basis der Messungen \bar{Z} berechnen wir für jedes Modell I die Likelihood $P(\bar{Z}|I)$ und die A-Priori-Wahrscheinlichkeit $P(I)$.

$P(I)$ hängt von der Anzahl der Fahrstreifen L_a^o bzw. L_a^i und Anzahl der Arme $|A|$ ab und wurde empirisch bestimmt. Die Breite der Lücke g_a , der Winkel zwischen den Armen

α_a und der Zentrumspunkt c werden mit nicht-informativen A-Priori-Wahrscheinlichkeiten versehen. Somit ergibt sich

$$P(I) = P(|A|)P(c) \prod_{a \in A} P(L_a^o)P(L_a^i)P(\alpha_a)P(g_a). \quad (5)$$

Für die Likelihood $P(\bar{z}|I)$ vergleichen wir jeden Trajektorienrepräsentanten \bar{z} mit der Zentrumslinie M_l der geschätzten Fahrstreifen, die zwischen dessen Rändern definiert ist. Dazu wird zunächst jede Trajektorie \bar{z} dem Fahrstreifen l zugeordnet, der die gleiche Fahrtrichtung wie $\bar{\mathbf{v}}$ besitzt und die kürzeste orthogonale Distanz zu $\bar{\mathbf{x}}$ aufweist. Die Likelihood selbst wird über die orthogonale Distanz $d_{\perp}(\bar{\mathbf{x}}, M_l)$ sowie die Winkeldistanz $d_{\triangleleft}(\bar{\mathbf{v}}, M_l)$ berechnet, die jeweils als normalverteilt angenommen werden. Somit ergibt sich

$$P(\bar{Z}|I) = \prod_{\bar{z} \in \bar{Z}} \sum_{l \in L} P_{\theta}(\bar{z}, l) P_{\perp}(\bar{\mathbf{x}}|M_l) P_{\triangleleft}(\bar{\mathbf{v}}|M_l), \quad (6)$$

wobei $P_{\theta}(\bar{z}, l)$ die Wahrscheinlichkeit angibt, dass die Messung \bar{z} dem Fahrstreifen l zugeordnet wird. Da hier zur Reduktion der Rechenzeit jede Messung genau einem Fahrstreifen zugeordnet wird, nimmt diese nur 0 oder 1 an.

Aufgrund der Konstruktion des Algorithmus und der Reduktion auf einen einzelnen Repräsentanten pro Trajektorienstück lässt sich die Grobschätzung alternativ auch mit unverfolgten Objekten und reinen Detektionen, wie bspw. von einem Doppler-Radar, durchführen. Dabei fällt lediglich die Winkeldistanz $d_{\triangleleft}(\bar{\mathbf{v}}, M_l)$ als Teil der Likelihood weg. Der Vorteil dieser Alternative ist die Möglichkeit, auf sämtliche Vorverarbeitung im Sinne einer Objekterkennung und -verfolgung verzichten zu können, wenn lediglich das grobe Layout einer Kreuzung benötigt wird.

3.2 Fahrstreifenschätzung

Im zweiten Schritt wird die optimale, grob geschätzte Kreuzung \hat{I} verwendet, um genaue Fahrstreifen L zu schätzen. Jeder Fahrstreifen wird dazu mit einem rechten und linken Rand modelliert, der jeweils aus einem Polygonzug mit equidistanten Stützpunkten besteht (siehe Abbildung 1b). Hieraus ergibt sich zudem eine Zentrumslinie, die zwischen den Randpunkten verläuft.

Algorithmus 2 Neue Fahrstreifenhypthesen werden durch Änderung jeweils eines Parameters erzeugt.

```

 $\omega \leftarrow \mathcal{U}[0, 1]$ 
if  $\omega < 0.67$  then
    verschiebe Zentrumslinie orthogonal zum Verlauf um  $\Delta m_l \leftarrow \mathcal{U}[-0,4 \text{ m}; 0,4 \text{ m}]$ 
else if  $\omega < 0.72$  then
    trenne Randpunkte; neuer Punkt  $\Delta b_l \leftarrow \mathcal{U}[-1,2 \text{ m}; 1,2 \text{ m}]$ 
else
    fusioniere zwei Randpunkte benachbarter Fahrstreifen zu einem Randpunkt
end if

```

Die Fahrstreifen werden mit Hilfe der Grobschätzung und der Trajektorien so initialisiert, dass sich alle Fahrstreifenpaare aus der Grobschätzung, die sich auf unterschiedlichen

Armen befinden und durch mindestens eine gemessene Trajektorie verbunden sind, auch durch einen Fahrstreifen innerhalb der Kreuzung verbunden werden. Anschließend wird, wie in der Grobschätzung, das Modell schrittweise mit den in Algorithmus 2 dargestellten Änderungsmöglichkeiten modifiziert.

Für die Bewertung der Fahrstreifen wird ebenfalls die A-Priori-Wahrscheinlichkeit $P(L)$ und die Likelihood $P(Z|L)$ für jede Trajektorie z berechnet. Hier werden jedoch im Gegensatz zur Grobschätzung alle Trajektorienpunkte $z_i = (\mathbf{x}, \mathbf{v})$ verwendet.

Die A-Priori-Wahrscheinlichkeit $P(L)$ wird aus der Anzahl der geteilten Randpunkte sowie der Glätte der Fahrstreifen als Summe der absoluten Winkelabweichungen zwischen aufeinanderfolgenden Zentrumsunkten berechnet.

Die Likelihood wird, wie bei der Grobschätzung, aus der orthogonalen Distanz $d_{\perp}(\mathbf{x}_i, M_l)$ sowie der Winkeldistanz $d_{\triangleleft}(\mathbf{v}_i, M_l)$ zwischen Trajektorienpunkt z_i und dem nächsten Fahrstreifen l in gleicher Richtung bestimmt. Wir nehmen für beides eine Normalverteilung an und erhalten

$$P(Z|I) = \prod_{z_i \in Z} \sum_{l \in L} P_{\theta}(z, l) P_{\perp}(\mathbf{x}_i | M_l) P_{\triangleleft}(\mathbf{v}_i | M_l). \quad (7)$$

Da hier ebenfalls mit $P_{\theta}(z, l)$ jede Messung genau einem Fahrstreifen zugeordnet wird, nimmt diese nur 0 oder 1 an.

4 Evaluation

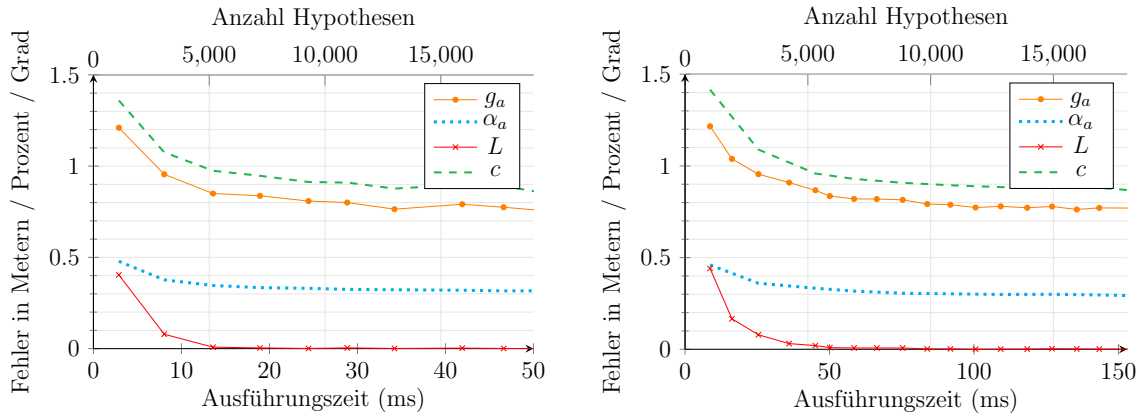
Für die Evaluation wurden 1 000 zufällige Kreuzungen simuliert. Dabei wurden die Parameter des Modells verwendet und Kreuzungen generiert, die zwischen drei und fünf Armen mit bis zu vier eingehenden und ausgehenden Fahrstreifen besitzen. Die Arme wurden dabei mit einem Abstand von mindestens 45° positioniert und der Abstand der Fahrstreifen kann bis zu 3 m betragen.

Zudem haben wir für 14 urbane Kreuzungen im Raum Karlsruhe Kartenmaterial erstellt. Diese wurden in zwei Kategorien aufgeteilt. Kreuzungen mit einem Fahrstreifen je Richtung werden als *kleine* und alle Übrigen als *große* Kreuzungen bezeichnet. Für sowohl synthetische als auch reale Kreuzungen wurden zufällige Fahrzeugtrajektorien simuliert, die die Zentrumslinien der Fahrstreifen befahren. Die einzelnen Messpunkte der Trajektorien wurden normalverteilt mit $\Delta z_i \leftarrow \mathcal{N}(0 \text{ m}; 1 \text{ m})$ verrauscht.

Für die Evaluation wurde zudem die kontinuierliche Aufnahme von Messungen vernachlässigt und stattdessen sämtliche Messungen auf einmal in die Schätzung aufgenommen. Dies hat den Vorteil, dass die Gesamtschätzung besser beurteilt werden kann.

Genauigkeit der Schätzung Um vergleichbare Experimente durchzuführen, wurden die Berechnungen auf eine bestimmte Stichprobenanzahl begrenzt und somit Ergebnisse nach 10 000 Stichproben in der Grobschätzung und nach 20 000 Stichproben in der Fahrstreifenschätzung analysiert. Die Ausführungszeiten für unterschiedlichen Anzahl Hypothesen und deren Genauigkeit in der Grobschätzung ist in Abbildung 2 dargestellt.

Für die Grobschätzung (siehe Tabelle 1) wurde jeder Parameter einzeln untersucht und es konnte festgestellt werden, dass die Anzahl der Arme in jeder Kreuzung richtig geschätzt wird. Die Anzahl der Fahrstreifen ist in allen Kreuzungen bis auf zwei bzw.



(a) Eine Trajektorie pro Fahrstreifen. (b) Drei bis fünf Trajektorien pro Fahrstreifen.

Abbildung 2: Entwicklung der Fehler über Ausführungszeit für 1 000 künstlich erzeugte Kreuzungen.

drei korrekt. Hier wurden im Fehlerfall Fahrstreifen zu viel geschätzt. Bis zum Zeitpunkt der Schätzung mit jeweils einer Trajektorie pro Fahrstreifen lief das Verfahren 28 ms. Bei der Hinzunahme von mehr Trajektorien erhöht sich die Ausführungszeit für eine Ad-Hoc-Schätzung, das heißt eine Schätzung ohne Vorwissen mit sämtlichen Messungen, auf 84 ms, wobei sich die Qualität der Schätzung nur um $0,02^\circ$ im Winkel und 1 cm in der Breite der Lücke zwischen den Fahrstreifen sowie dem Zentrum verbessert. Dies zeigt, dass bereits mit wenigen Daten eine sehr gute Schätzung durchgeführt werden kann.

Zur Evaluation der genauen Fahrstreifen (siehe Tabelle 1) wurden die geschätzten Zentrumslinien mit denen der Kartendaten verglichen und hierfür die durchschnittliche, orthogonale Distanz E verwendet. 20 000 Hypothesen sind hier nur nötig, wenn die Fusion der Fahrstreifenränder von Bedeutung ist, da die Positionierung der Fahrstreifen nach wenigen Schritten konvergiert und lediglich die Fusion mehr Schritte benötigt.

Auf den 14 realen Kreuzungen können für beide Schätzungen vergleichbare Ergebnisse schneller berechnet werden, da diese deutlich weniger Fahrstreifen aufweisen (siehe Tabelle 1). Die Ergebnisse für drei reale Kreuzungen aus Karlsruhe zeigt Abbildung 3.

Tabelle 1: Genauigkeit der Grobschätzung ① und Fahrstreifenschätzung ②. Die Tabellen zeigen zudem den Vergleich zwischen Experimenten mit einer Messung pro Fahrstreifen und drei bis fünf Messungen. Ergebnisse werden angegeben als Ausführungszeit in Millisekunden, Winkelabweichung in Grad, Anzahl Kreuzungen mit fälschlicher Anzahl Fahrstreifen und Abweichung der Lücke sowie des Zentrums in Zentimetern.

①	Synth				
	ms	α	L	g	c
1 T	28	$0,3^\circ$	3	80	91
3-5 T	84	$0,3^\circ$	2	79	90

②	Synth		Real Klein		Real Groß	
	ms	E	ms	E	ms	E
1 T	104	14	78	18	89	27
3-5 T	173	9	110	11	137	19




Abbildung 3: Ergebnisse der Schätzung von realen Kreuzungen in Karlsruhe¹

Abhängigkeit von der Anzahl an Messungen Zur Evaluation der Robustheit des Ansatzes, haben wir untersucht, welche Änderungen sich zwischen vielbefahrenen Kreuzungen und weniger frequentierten Kreuzungen ergeben. Dazu wurde die Schätzung zunächst auf lediglich einer Trajektorie pro Fahrstreifen ausgeführt und zum Vergleich ein Experiment mit drei bis fünf Trajektorien pro Fahrstreifen als Messung in die Schätzung aufgenommen. Abbildung 2 veranschaulicht den unterschiedlichen Verlauf dieser Experimente für die Grobschätzung. Hier ist klar ersichtlich, dass zur Konvergenz zwar ähnlich viele Hypothesen generiert werden müssen, diese jedoch deutlich schneller berechnet werden können, wenn weniger Messungen vorhanden sind. Dabei erhöht sich die Verarbeitungszeit zwischen den beiden Experimenten von $3 \mu\text{s}$ pro Hypothese auf $8 \mu\text{s}$. Die Qualität der Ergebnisse ändert sich jedoch nur marginal, solange nicht ein starkes Messrauschen oder sehr unterschiedliche Fahrweisen vorliegen, die sich mit mehr Messungen pro Fahrstreifen leichter ausgleichen lassen. In der anschließenden Fahrstreifenschätzung (siehe Tabelle 1) werden pro Hypothese $4 \mu\text{s}$ bzw. $9 \mu\text{s}$ benötigt, wobei sich die Ergebnisse durch mehr Trajektorien um wenige Zentimeter verbessern.

5 Diskussion

In dieser Arbeit wurde ein Ansatz vorgestellt, mit dem während der Fahrt das Kreuzungslayout sowie der Verlauf einzelner Fahrstreifen geschätzt werden können. In der Evaluation konnte gezeigt werden, dass selbst eine Ad-Hoc-Schätzung weniger als 180 ms benötigt.

Im Online-Einsatz nimmt die Kreuzungsschätzung, im Gegensatz zu dem in der Evaluation verwendeten Konzept der Einmal-Beobachtung, kontinuierlich Messungen auf. Dabei stehen zunächst nur wenige Trajektorien zur Verfügung, mit Hilfe derer jedoch bereits eine grobe Schätzung der Kreuzung erfolgen kann. Je mehr Fahrzeuge die Kreuzung befahren und somit je mehr Messungen in die Schätzung aufgenommen werden, desto stabiler kann eine valide Kreuzungshypothese gefunden werden. Dies bedeutet im Umkehrschluss, dass zwar für eine Schätzung einer Kreuzung mit bspw. einer Abweichung von lediglich 8 cm mehr als 100 ms benötigt werden, diese Zeit sich jedoch auf eine vollständige Neuschätzung bezieht. In der praktischen Anwendung des vorgestellten Ansatzes kom-

¹Luftbilder: Stadt Karlsruhe, www.karlsruhe.de, dl-de/by-2-0

men kontinuierlich neue Messungen hinzu und eine neue Schätzung wird in regelmäßigen Abständen angestoßen, jedoch wird dabei die vorherige Modellschätzung beibehalten. Dadurch führen neue Messungen zwar zur Verlangsamung der Berechnung jedoch auch zur Verfeinerung der Hypothese. Eine initiale Schätzung ist bereits mit sehr wenigen Messungen möglich und reduziert somit bereits den nötigen zu untersuchenden Hypothesenraum für folgende Schätzungen.

Im Falle von ampelgesteuerten Kreuzungen kommt zudem hinzu, dass eine Rot-Phase Messungen in einem Zeitraum von mehreren Sekunden ermöglicht und somit eine äußerst präzise Schätzung erfolgen kann.

Literatur

- [1] Y. Hou, Z. Ma, C. Liu, and C. C. Loy, “Learning Lightweight Lane Detection CNNs by Self Attention Distillation,” in *The IEEE International Conference on Computer Vision (ICCV)*, pp. 1013–1021, 2019.
- [2] N. Homayounfar, W.-C. Ma, J. Liang, X. Wu, J. Fan, and R. Urtasun, “DAGMapper: Learning to Map by Discovering Lane Topology,” in *The IEEE International Conference on Computer Vision (ICCV)*, pp. 2911–2920, 2019.
- [3] D. Barnes, W. Maddern, and I. Posner, “Find Your Own Way: Weakly-Supervised Segmentation of Path Proposals for Urban Autonomy,” in *2017 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 203–210, 2017.
- [4] A. Amini, G. Rosman, S. Karaman, and D. Rus, “Variational End-to-End Navigation and Localization,” in *2019 International Conference on Robotics and Automation (ICRA)*, pp. 8958–8964, 2019.
- [5] O. Roeth, D. Zaum, and C. Brenner, “Road network reconstruction using reversible jump MCMC simulated annealing based on vehicle trajectories from fleet measurements,” in *2016 IEEE Intelligent Vehicles Symposium (IV)*, pp. 194–201, 2016.
- [6] A. Geiger *et al.*, “3D Traffic Scene Understanding from Movable Platforms,” *IEEE Trans. on Pattern Analysis and Mach. Intell.*, vol. 36, no. 5, pp. 1012–1025, 2014.
- [7] J. Liang, N. Homayounfar, W.-C. Ma, S. Wang, and R. Urtasun, “Convolutional Recurrent Network for Road Boundary Extraction,” in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 9512–9521, 2019.
- [8] O. Roeth, D. Zaum, and C. Brenner, “Extracting Lane Geometry and Topology Information from Vehicle Fleet Trajectories in Complex Urban Scenarios Using a Reversible Jump MCMC Method,” in *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. IV-1-W1, pp. 51–58, 2017.
- [9] C. Andrieu, N. De Freitas, A. Doucet, *et al.*, “An Introduction to MCMC for Machine Learning,” *Machine learning*, vol. 50, no. 1-2, pp. 5–43, 2003.
- [10] N. Metropolis, A. W. Rosenbluth, M. N. Rosenbluth, *et al.*, “Equation of State Calculations by Fast Computing Machines,” *The J. of Chemical Physics*, vol. 21, no. 6, pp. 1087–1092, 1953.