

# Planungsbasierte Fußgängerprädiktion

Eike Rehder\*, Horst Klöden† und Christoph Stiller‡

**Zusammenfassung:** Während die Unfallzahlen stetig sinken, bleibt die Zahl verletzter Fußgänger im Straßenverkehr nahezu konstant. Um dem mit aktivem Fußgängerschutz entgegenzuwirken, ist eine Prädiktion unerlässlich. In dieser Arbeit wird ein Verfahren zur dynamik- und umfeldbasierten Prädiktion vorgestellt. Hierfür werden Ziele als latente Variablen eingeführt, zu denen mithilfe eines Bewegungsmodells eine Pfadverteilung geplant wird. Ein Partikelfilter übernimmt die Verwaltung der Ziele. Ergebnisse zeigen eine deutliche Verbesserung der Prädiktion gegenüber reinen Dynamikmodellen wie etwa einem Kalman-Filter.

**Schlüsselwörter:** Fußgängerschutz, Prädiktion, Intentionserkennung

## 1 Einleitung

Neueste Fortschritte in der Fußgängerdetektion lassen den aktiven Fußgängerschutz in greifbarer Nähe erscheinen. Hierfür ist es allerdings unerlässlich, deren Bewegung prädictieren zu können.

In bisherigen Systemen wurde die Prädiktion auf Basis von Dynamikinformationen durchgeführt, also meist durch eine Extrapolation der bisherigen Bewegungsmuster. Allerdings können Fußgänger sehr dynamisch ihre Bewegungszustände wechseln, sodass mit steigenden Zeithorizonten die Unsicherheit der Prädiktion über ein vertretbares Niveau ansteigt.

Hier zeigt sich, dass allein dynamikbasierte Prädiktion nicht zielführend sein kann. Menschliches Handeln ist meist von einer bestimmten Motivation getrieben. So bewegen sich Fußgänger aus der Absicht heraus, ein bestimmtes örtliches Ziel zu erreichen. Problemstellung dieser Art sind bereits aus der Robotik bekannt: ein Mensch kann als ein Agent aufgefasst werden, der nach bestimmten Gesichtspunkten seinen Pfad zu einem Ort plant. Durch diese Annahme kann das Prädiktionsproblem von einer reinen Vorhersage über den Bewegungszustand in ein Planungsproblem umgewandelt werden.

Für dieses Planungsproblem muss zunächst ein Modell über die Umgebung angefertigt werden, in dessen Rahmen dann die Planung ausgeführt werden kann. Hier zeigt sich ein weiterer Vorteil planungsbasierter Fußgängerprädiktion gegenüber der reinen Dynamik: Informationen über die Umgebung wie z.B. Hindernisse, Fußwege, etc., können in der Prädiktion mit berücksichtigt werden.

---

\*eike.rehder@kit.edu, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT)

†horst.kloeden@bmw.de, BMW Group Forschung und Technik, München

‡stiller@kit.edu, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT)

Ist nun der Aufenthaltsort eines Fußgängers in seiner Umgebung bekannt, kann durch Planung zu seinem örtlichen Ziel sein weiter Bewegungspfad vorhergesagt werden. Dem Ziel kommt dabei eine besondere Bedeutung bei: es spiegelt die Intention eines Fußgängers wider, also z.B. die Absicht, eine Straße zu überqueren oder auf dem Fußweg zu verbleiben. Von außen betrachtet ist diese Intention allerdings unbekannt, dies bedeutet, dass sie zur Prädiktionszeit als latente Variable mitgeführt werden muss.

In dieser Arbeit soll eine Verteilung über die zukünftigen Aufenthaltsorte eines Fußgängers durch Planung gewonnen werden. Ein Fußgänger sei dabei repräsentiert durch seinen Zustand  $X_t$  in Position  $(x_t, y_t)$  und Orientierung  $\nu_t$  zur Zeit  $t$ ,  $X_t = (x_t, y_t, \nu_t)^\top$ . Durch Tracking sei auch die Vergangenheit der Zustände  $X^t = (X_t, X_{t-1}, \dots, X_0)$  bekannt. Zusätzlich sei eine Karte der Umgebung  $\Theta_t$ , gegeben durch ein Belegungsgitter, verfügbar.

Als latente Variable werden kurzfristig zu erreichende Ziele  $X_T$  eingeführt. Die Verwendung dieser Zielzustände erlaubt es, eine zielgerichtete Planung auszuführen, sodass die Verteilung  $p(X^T|X^t, X_T, \Theta_t)$  als Prädiktion geschätzt werden kann.

Durch Marginalisierung über mögliche Zielzustände wird die Verteilung

$$p(X^T|X^t, \Theta_t) \quad (1)$$

der zukünftigen Fußgängerzustände bis zum Zeitpunkt  $T$  geschätzt. In nachfolgenden Zeitschritten kann die initiale Prädiktion mit der tatsächlichen Bewegung abgeglichen werden. Dies erlaubt eine rekursive Verbesserung der Zielannahmen, sodass als Nebenprodukt die Intention des Fußgängers in Form seines Bewegungsziels inferiert werden kann.

## 2 Stand der Forschung

Die Prädiktion von Fußgängern gewinnt mit zunehmender Güte von Detektionsverfahren immer mehr an Bedeutung. Generell kann zwischen kurzzeitiger Prädiktion im Bereich von Zehntelsekunden und Langzeitprädiktion mit Zeithorizonten von mehreren Sekunden unterschieden werden.

Im Bereich der Kurzzeitprädiktion wird meist Gebrauch von rekursiven Schätzverfahren gemacht, die die bisherige Bewegung des Fußgängers modellbasiert extrapolieren. Zu den verbreitetsten Verfahren gehören Kalman-Filter (KF und EKF) [11] sowie Partikelfilter (PF) [1]. Als Erweiterung der sonst starren Modellannahme werden interagierende Modelle verwendet, bei denen mehrere Bewegungsmodelle gleichzeitig verwendet werden [8]. Auch werden Gauß'sche dynamische Modelle verwendet [5, 10]. Ein Sonderfall der Kurzzeitprädiktion beschäftigt sich mit der Frage nach der Änderung des Bewegungszustands, also z.B. Stehen gegenüber Gehen [12] oder das Betreten der Straße [9].

Im Bereich der Langzeitprädiktion wird meist die Bewegung eines Fußgängers anhand von zuvor beobachteten Trajektorien in eine Klasse von Bewegungsmustern eingeordnet und damit prädiziert [2, 3, 6]. Auch planungsbasierte Prädiktion anhand von Umgebungseinflüssen wird verwendet [13, 4, 7].

## 3 Zielgerichtete Fußgängerprädiktion

Für die Repräsentation der Verteilung  $p(X^T|X^t, \Theta_t)$  wird ein Belegungsgitter verwendet. Der Zustandsraum wird in die drei Dimensionen Ort  $(x_t, y_t)$  und Orientierung  $\nu_t$  diskretisiert.

Die Diskretisierung des Raumes erlaubt es, die Verteilung über den Aufenthaltsort des Fußgängers parameterfrei anzunähern. Gegenüber parametrischen Modellen bringt dies den Vorteil mit sich, dass eine Vielzahl von multimodalen Verteilungen dargestellt werden kann, wie sie sich zum Beispiel durch Hindernisse im Weg des Fußgängers ergeben.

Darüber hinaus wird die Markov-Annahme getroffen, sodass  $p(X_{t+1}|X^t) = p(X_{t+1}|X_t)$  gilt. Ein Gitter für die Verteilung  $p(X_t|X_{t-1})$  sei bezeichnet mit  $\Phi_t$ . Der aktuelle Zeitpunkt wird als  $t = 0$  definiert,  $p(X_0)$  sei aus dem Tracking bekannt.

### 3.1 Prädiktionsmodell

Für die Prädiktion ist zunächst der Übergang einer Verteilung zum Zeitpunkt  $t$  nach  $t + 1$  von Interesse. Dies entspricht der Übergangsverteilung zwischen zwei aufeinanderfolgenden Gittern. Wie bereits erwähnt, wird die Markov-Annahme getroffen, die hier durch ein Bewegungsmodell abgebildet wird. Dieses Bewegungsmodell sei repräsentiert durch

$$X_t = X_{t-1} + u(v_t, \nu_t), \quad (2)$$

wobei  $u(v_t, \nu_t)$  einen Bewegungsvektor bezeichnet, der sich aus der Geschwindigkeit  $v_t$  des Fußgängers und seiner Ausrichtung  $\nu_t$  berechnet, hier

$$u(v_t, \nu_t) = (\Delta_t v_t \cos \nu_t, \Delta_t v_t \sin \nu_t, \nu_t)^\top. \quad (3)$$

Diese Annahme entspricht einer linearen Bewegung mit konstanter Geschwindigkeit entlang einer konstanten Bewegungsrichtung.

Sind sowohl  $X_{t-1}$  als auch  $u(v_t, \nu_t)$  Zufallsgrößen, so gilt für die Verteilung von  $X_t$

$$p(X_t|X_{t-1}) = p(X_{t-1}) \otimes p(u(v_t, \nu_t)), \quad (4)$$

d.h. eine Faltung der Verteilung zum vorigen Zeitpunkt mit der des Bewegungsvektors.

Für die Modellierung der Verteilung von  $u(v_t, \nu_t)$  werden die Geschwindigkeit  $v_t$  und Orientierung  $\nu_t$  als unabhängig betrachtet. Die Geschwindigkeit sei normalverteilt mit bekanntem Mittelwert und Varianz, die Orientierung  $\nu_t$  wird als von-Mises-verteilt mit bekanntem Mittelwert und Konzentrationsparameter  $\kappa_{\Delta\nu}$  angenommen. Zudem sei eine Bewegung nicht entlang der Orientierung von-Mises-verteilt mit Mittelwert Null und Konzentrationsparameter  $\kappa_v$ .

$$\begin{aligned} p(\Delta x, \Delta y, \Delta\nu) \propto & \exp\left(-\frac{(\Delta x - \Delta t v \cos(\nu))^2}{2\sigma_v^2}\right) \\ & \cdot \exp\left(-\frac{(\Delta y - \Delta t v \sin(\nu))^2}{2\sigma_v^2}\right) \\ & \cdot \exp(\kappa_{\Delta\nu} \cos(\Delta\nu)) \\ & \cdot \exp(\kappa_v \cos(\angle(\Delta y, \Delta x) - \nu)) \end{aligned} \quad (5)$$

Auf das Belegungsgitter diskretisiert, ergibt sich aus der Verteilung (5) die diskrete Faltungsmaske  $A$ . Die Verteilung  $\Phi_t$  wird aus ihrem Vorgänger  $\Phi_{t-1}$  durch eine diskrete Faltung berechnet aus

$$\Phi_t \propto A \otimes \Phi_{t-1}. \quad (6)$$

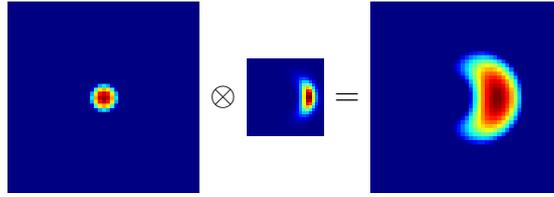


Abbildung 1: Faltung einer Initialverteilung mit Prädiktionsmaske und Endergebnis

Die Gitter  $\Phi_t$  sind nun als die Wahrscheinlichkeitsverteilung über den Zustand  $X_t$  zu verstehen, den ein Fußgänger in  $t$  Zeitschritten bei gegebener Bewegung erreicht haben kann. Durch den großen Anteil unbesetzter Zellen in sowohl der Vorgänger- als auch der Bewegungsverteilung lässt sich die Faltung effizient durch spärliche Matrizen berechnen.

Abbildung 1 zeigt beispielhaft einen einzelnen Faltungsschritt. Dabei ist die Aufenthaltsverteilung des Fußgängers in  $x$ - und  $y$ -Richtung normalverteilt mit dem Mittelwert in der Mitte der Karte initialisiert, die Ausrichtung ist von-Mises-verteilt mit Mittelwert Null. Daraus ergibt sich eine Ausrichtung nach rechts, was sich auch in der resultierenden Faltungsmaske niederschlägt. Das Ergebnis der Faltung ist dann eine nierenförmige Verteilung nach rechts verschoben, wie auch eine Fußgängerbewegung zu erwarten wäre.

### 3.2 Zielgerichtete Prädiktion

Bisher wurde lediglich eine allgemeine probabilistische Prädiktion vorgenommen. Da allerdings die Bewegung eines Fußgängers zielgerichtet ist, sollte dies in der Prädiktion ebenfalls berücksichtigt werden. Hierfür wird die bereits vorgestellte Prädiktion erweitert, um genau diesen Umstand abzubilden.

Es wird zunächst angenommen, die Verteilung  $p(X_T)$  über den Zielzustand des Fußgängers zum Zeitpunkt  $T$  sei bekannt. Diese Annahme ist in der Einführung von  $X_T$  als latente Variable begründet.

Zunächst wird wieder ein diskretisiertes Gitter  $\Phi_T$  angelegt. Dieses wird als initiale Annahme für eine rückwärts gerichtete Prädiktion verwendet. Hierfür wird die Verteilung (5) invertiert, sodass ein Faltungsmaske  $A^{-1}$  gewonnen werden kann. Die rückwärtsgerichtete Prädiktion berechnet sich dann zu

$$\Phi_{t-1} \propto A^{-1} \otimes \Phi_t. \quad (7)$$

Gleichung (7) beschreibt also eine Verteilung über den Fußgängerzustand  $X_t$  zum Zeitpunkt  $t$ , der bei gegebener Bewegung zum Zeitpunkt  $T$  den Zustand  $X_T$  erreichen wird.

Unter der Annahme, Ausgangszustand  $X_0$  und Zielzustand  $X_T$  seien statistisch unabhängig, ist der Pfad, den ein Fußgänger von  $X_0$  zu  $X_T$  wählt, die Kombination der vorwärts und rückwärts gerichteten Prädiktion. Sei  $\Phi_t^+$  also die aus (6) gewonnene Prädiktion für den Zeitpunkt  $t$  und  $\Phi_t^-$  äquivalent die aus der inversen Prädiktion gewonnene, so ergibt sich

$$p(X_t|X_0, X_T) \propto \Phi_t^+ \Phi_t^-. \quad (8)$$

Dies bedeutet, dass durch iterative Faltung in Vorwärts- und Rückwärtsrichtung und Multiplikation der Ergebnisse die Verteilung  $p(X_t|X_0, X_T)$  berechnet werden kann.

### 3.3 Umgebungseinfluss

Für die langfristige Bewegung von Fußgängern spielt neben der Dynamik auch die Umgebung eine bedeutende Rolle. Dies spiegelt sich z.B. bei Objekten wie parkenden Fahrzeugen wider, die ein Fußgänger nicht durchqueren kann. Darüber hinaus verhält sich ein Fußgänger beim Überqueren einer Straße anders als beim Gehen auf einem Gehweg.

Aus diesen Überlegungen heraus soll also auch die Umgebung in die Planung einbezogen werden. Dafür wird eine *a-priori*-Verteilung  $p(X_t|\Theta_t)$  berechnet, mit der die Prädiktion modifiziert wird zu

$$\Phi_t^+ \propto p(X_t|\Theta_t) (A \otimes \Phi_{t-1}^+) \quad \text{und} \quad (9)$$

$$\Phi_{t-1}^- \propto p(X_t|\Theta_t) (A^{-1} \otimes \Phi_t^-). \quad (10)$$

Der Term  $p(X_t|\Theta_t)$  in (9) und (10) repräsentiert anschaulich die Wahrscheinlichkeit, dass ein Fußgänger eine Gitterzelle mit bestimmten Eigenschaften betreten wird. So ergibt sich z.B., dass ein Fußgänger eine Zelle, die bereits von einem anderen Objekt belegt ist, nur mit geringer Wahrscheinlichkeit betritt.

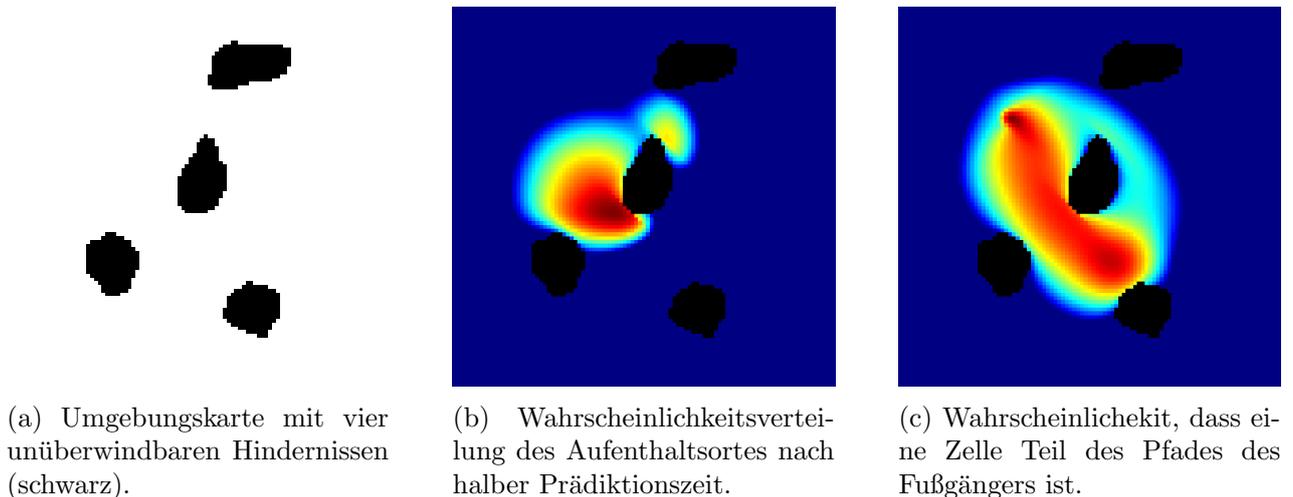


Abbildung 2: Verwendung einer Umgebungskarte: Karte, Zwischenverteilung und resultierende Pfadverteilung. Blau entspricht niedriger, rot hoher Aufenthaltswahrscheinlichkeit.

Die *a-priori*-Verteilung  $p(X_t|\Theta_t)$  wird in Form eines Belegungsgitters mit Diskretisierung analog zu  $\Phi_t$  geschätzt. Die Schätzung erfolgt dabei zellenweise aus Merkmalen eines Gitters  $\Theta_t$ . Das Gitter  $\Theta_t$  enthält dabei verschiedene Merkmale, die in die Verteilungsschätzung einfließen. Sei  $\theta_i$  der Vektor aller Merkmale der Zelle  $i$ , so wird die *a-priori*-Wahrscheinlichkeit  $p(X_i|\theta_i)$  abgeschätzt mit der Sigmoidfunktion

$$p(X_i|\theta_i) = \frac{1}{1 + \exp(-a^T \theta_i)}, \quad (11)$$

wobei der Vektor  $a^T$  Gewichtungparameter der einzelnen Merkmale darstellt.

Die Gewichte  $a^T$  werden anhand von bekannten Fußgängertrajektorien gelernt. Hierfür sei ein Satz von  $N$  Trajektorien  $(\zeta_1, \dots, \zeta_N)$  mit  $M$  Einzelmessungen  $\zeta_i = \{X_1, \dots, X_M\}$  zusammen mit den dazugehörigen Belegungsgittern  $\Theta_i$  bekannt. Es wird nun für jede

Trajektorie die Planung gemäß (8) mit (9) und (10) ausgeführt und in einen Pfad umgewandelt, um zunächst unabhängig von der zeitlichen Komponente sein zu können. Für die Pfadverteilung werden die Gegenwahrscheinlichkeiten des Aufenthaltsortes zu allen Zeitpunkten herangezogen, sodass das Ergebnis

$$p(X^t|X_0, X_T, \Theta_t) = 1 - \prod_{\tilde{t}=0}^M (1 - p(X_{\tilde{t}}|X_0, X_T, \Theta_t)) \quad (12)$$

die Wahrscheinlichkeit bezeichnet, dass ein Fußgänger auf dem Pfad von  $X_0$  zu  $X_T$  sich jemals in einer Zelle  $X$  befindet (s. z.B. Abb. 2c).

Dieser Pfad wird dann auf der Grundwahrheit der bekannten Trajektorie ausgewertet. Dies entspricht der prädizierten Wahrscheinlichkeit des tatsächlichen Pfades. Für die Optimierung der Parameter soll diese maximiert werden, d.h. die Prädiktion soll den tatsächlichen Pfad mit möglichst großer Wahrscheinlichkeit vorhersagen. Diese Problem ist äquivalent zur Minimierung des negativen Logarithmus der Pfadwahrscheinlichkeit

$$J(a) = - \sum_{\zeta_i \in X_j \in \zeta_i} \log(p(X = X_j|X_0, X_T, \Theta_t)). \quad (13)$$

### 3.4 Zielmodell

Für die bisherige Prädiktion wurde das Ziel  $X_T$  des Fußgängers als bekannt angenommen. In der Realität ist dies allgemein nicht der Fall, daher wird das Ziel als eine latente Variable behandelt. Die Schätzung der Verteilung der Ziele erfolgt mittels eines Partikelfilters. Dabei repräsentiert Jeweils ein Partikel ein Ziel mitsamt der dazugehörigen Prädiktionsplanung. Über die Gewichte der Partikel kann dann die prädizierte Verteilung berechnet werden.

Durch die Verwendung mehrerer Ziele können zudem multiple Hypothesen für das Fußgängerverhalten zu jedem Zeitpunkt verarbeitet werden, so kann z.B. ein Partikel den Fall abbilden, dass der Fußgänger eine Straße quert, während ein weiteres repräsentiert, dass er sich weiterhin auf dem Gehweg befindet.

Für die Filterung werden zunächst Ziele gleichverteilt initialisiert und die Planung gemäß (8) ausgeführt. Hiermit liegen nun Prädiktionen im Gitter vor, die im nachfolgenden Schritt mit der tatsächlichen Bewegung abgeglichen werden können.

Hierfür sei  $p(X_t^+)$  die geschätzte Aufenthaltsverteilung des Fußgängers zum Zeitpunkt  $t$ , während  $p(X_t|X_0, X_T, \Theta_t)$  der prädizierten Verteilung für diesen Zeitpunkt entspricht. Unter Anwendung des Satzes von Bayes ergibt sich zunächst

$$p(X_t|X_0, X_T, \Theta_t) \propto p(X_0, X_T, \Theta_t|X_t). \quad (14)$$

Wird nun über die aktuelle Messung  $X_t^+$  marginalisiert, gilt unter Zuhilfenahme der Unabhängigkeitsannahme, äquivalent zu (8),

$$p(X_T) \propto \int p(X_0, X_T, \Theta_t|X_t^+) p(X_t^+) dX_t^+. \quad (15)$$

Die Verteilung (15) wird nun für die jeweiligen Zielpartikel ausgewertet, um diese neu zu gewichten. Unwahrscheinliche Ziele können nun verworfen und in der Umgebung der bestehenden Ziele neu gezogen werden.

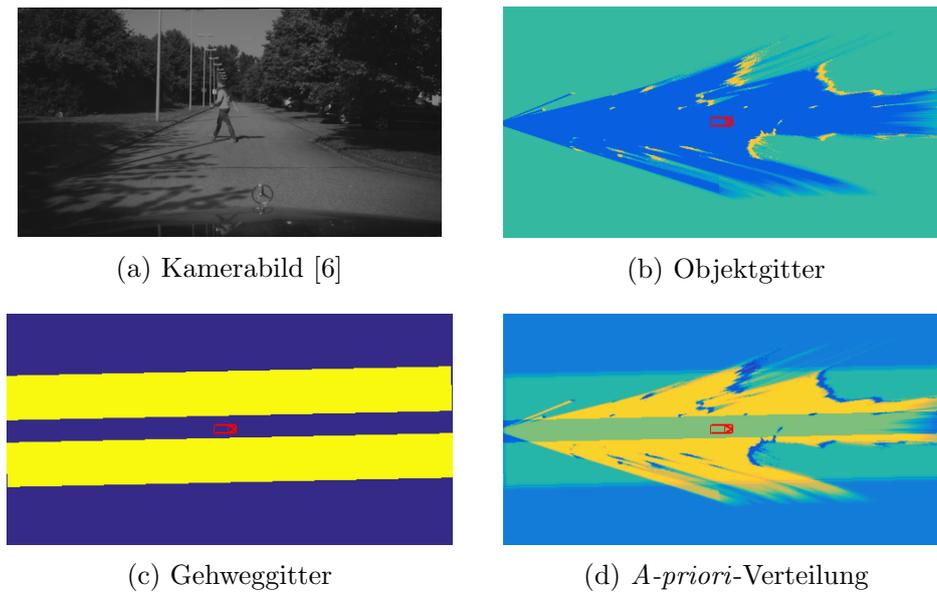


Abbildung 3: Merkmalsgitter und resultierende  $a$ -priori-Verteilung. Blau entspricht niedriger, gelb hoher Wahrscheinlichkeit.

## 4 Ergebnisse

Die vorgestellte Prädiktion wurde anhand des in [6] vorgestellten Datensatzes evaluiert. Hierfür wurden aus Stereokamerabildern Belegungsgitter für Objekte aufgezeichnet. Zusätzlich wurden Belegungsgitter für Straße, Gehweg und Bordsteine synthetisch aus der Annahme eines linearen Straßenverlaufs erzeugt. Sowohl die Trainings- als auch die Testdaten wurden in Untersequenzen von vier Sekunden Länge aufgeteilt.

Für das Training wurden sowohl die Parameter des Bewegungsmodells (5) als auch die Parameter der  $a$ -priori-Verteilung gemäß (13) auf den Trainingstrajektorien optimiert. Als Merkmale für den Umgebungseinfluss dienten neben einem Bias-Term und den originalen Belegungskarten auch weichgezeichnete Varianten der einzelnen Belegungsmerkmale, um z.B. bevorzugte Abstände von Objekten abbilden zu können.

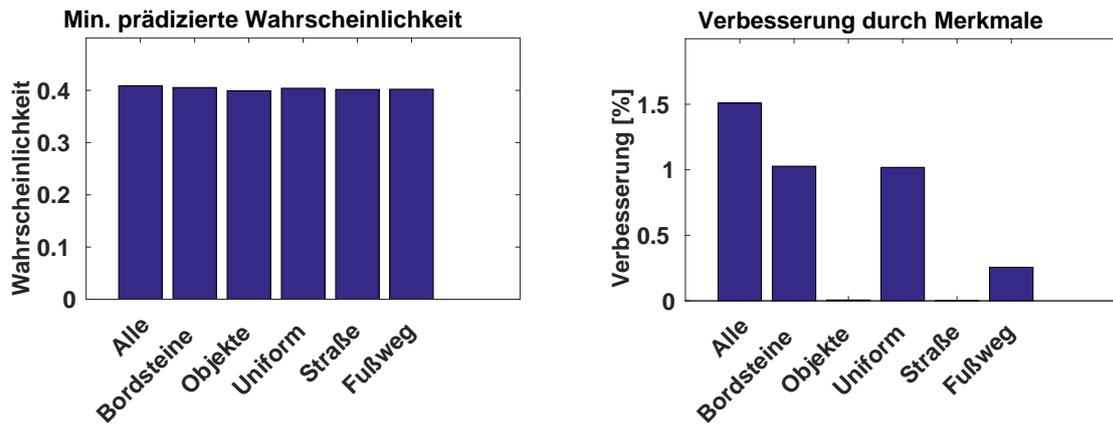
Ein Kamerabild einer Szene zusammen mit den resultierenden Belegungsgittern und der geschätzten Verteilung sind in Abbildung 3 dargestellt.

Für die Bewertung wird die prädizierte Wahrscheinlichkeit der tatsächlichen Trajektorie ausgewertet. Dieses Maß entspricht der Sicherheit der Prädiktion, mit der die Fußgängerbewegung vorhergesagt werden kann. Für die jeweiligen Ergebnisse wurden die Prädiktionsgüten der Einzelsequenzen gemittelt.

### 4.1 Prädiktion

Zunächst wird die reine Prädiktion mit verschiedenen Umgebungsmerkmalen bewertet. Dafür werden mithilfe der wie oben beschrieben aufbereiteten Trainingsdaten die Parameter trainiert und dann auf den Testdaten bewertet. Dabei wird der Pfad des Fußgängers aus der Grundwahrheit entnommen und Start- und Zielverteilung entsprechend initialisiert. Gegeben dieser Verteilungen wird dann (13) gradientenbasiert minimiert.

In Abb. 4 sind die Ergebnisse der Prädiktion ausgewertet auf der Grundwahrheitstra-



(a) Minima der Wahrscheinlichkeitsverteilung ausgewertet auf der Grundwahrheit unter Verwendung verschiedener Umgebungsmerkmale.

(b) Verbesserung der Prädiktion durch Merkmale, relativ zum niedrigsten Ergebnis: Straße

Abbildung 4: Bewertung der Prädiktion bei bekanntem Ziel.

jektorie des Fußgängers dargestellt. Dabei zeigt Abb. 4a jeweils die Minima der prädizierten Verteilungen nach Verwendung der angegebenen Merkmale für die Umgebungsverteilung. Es zeigen sich nur minimale Unterschiede, was besonders dem Umstand geschuldet ist, dass das Ziel in diesem Vergleich ja bereits eindeutig bekannt war. Um die Verbesserung der Prädiktion durch verschiedene Merkmale besser erkennbar zu machen, wird in Abb. 4b die Verbesserung bezogen auf die schwächsten Merkmale der Straße betrachtet. Hier zeigt sich, dass die Güte der Prädiktion durch geeignetere Merkmale um lediglich 1,5% gesteigert werden konnte. Außerdem kann die Verwendung von ungenauen Merkmalen, wie z.B. der Straßenmerkmale, sogar zu einer Verschlechterung gegenüber einer uniformen *a-priori*-Verteilung führen.

## 4.2 Zielinferenz

Nachdem die Parameter der Prädiktion im vorigen Schritt bestimmt worden sind, werden diese nun für die Prädiktion mit unbekanntem Ziel verwendet. Wieder werden die zugeschnittenen Testdaten verwendet. Allerdings wird von den vier Sekunden Sequenzlänge für eine Sekunde die rekursive Schätzung ausgeführt und dann für die verbleibende Zeit ausgewertet. Da zunächst nur Prädiktionshorizonte von drei Sekunden betrachtet wurden und eine davon bereits auf die rekursive Schätzung entfällt, verbleiben zwei Sekunden Prädiktion. Für den Vergleich sind zusätzlich die Ergebnisse eines Kalman-Filters mit dem Modell konstanter Geschwindigkeit dargestellt.

Abbildung 5 zeigt die Ergebnisse der Prädiktion nach rekursiver Schätzung. Betrachtet man zunächst die prädizierte Wahrscheinlichkeit als Funktion des Prädiktionshorizontes (Abb. 5a), so zeigt sich wieder, dass die Einflüsse der Merkmale gering, allerdings deutlicher sind als im Fall der bekannten Ziele (12% gegenüber 1,5%). Dies deutet darauf hin, dass die Bewegungsprädiktion zwar unscharf bleibt, allerdings Bewegung im Kontext von Umweltmerkmalen besser auf die tatsächliche Intention des Fußgängers schließen lässt. Weiterhin zeigt sich, dass eine zielgerichtete Prädiktion besonders auf lange Prädiktionssicht dem reinen Dynamikmodell des Kalman-Filters deutlich überlegen ist (Abb. 5b).

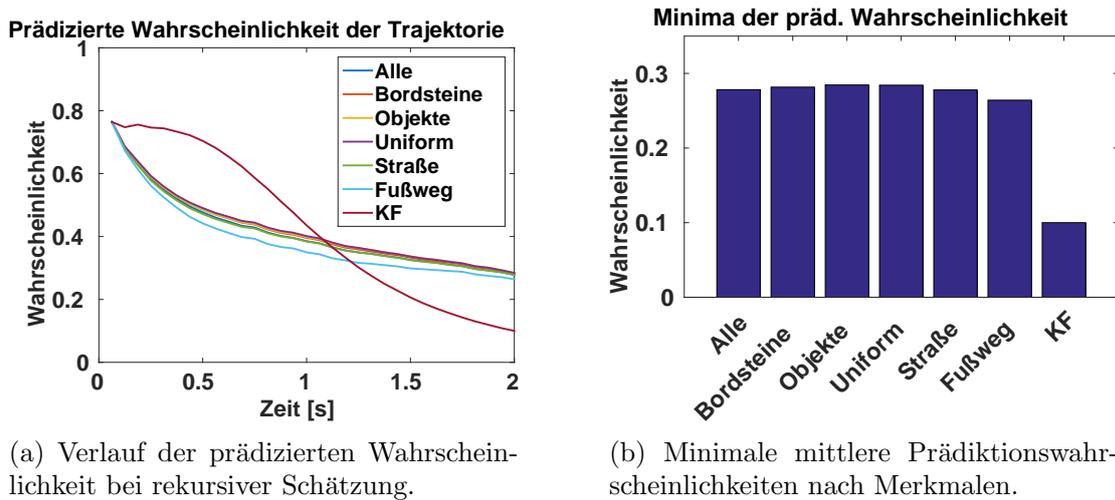


Abbildung 5: Bewertung der rekursiven Prädiktion mit latenten Zielen.

Zwar sind zu Beginn der Prädiktion Diskretisierungsartefakte aus dem Gitter zu erkennen, die sich z.B. in der schneller abfallenden Prädiktionsicherheit abzeichnen. Trotzdem ist selbst mit den schwächsten Merkmalen bei Prädiktionszeiträumen von über einer Sekunde die zielgerichtete Prädiktion dem KF überlegen.

## 5 Zusammenfassung und Ausblick

In dieser Arbeit wurde ein Verfahren zur intentionsgetriebenen probabilistischen Prädiktion von Fußgängern vorgestellt. Durch die Schätzung von örtlichen Zielen eines Fußgängers als latente Variable wurde das Prädiktionsproblem in ein Planungsproblem umgewandelt. Zusätzlich konnte der Einfluss der Umgebung auf die Fußgängerbewegung berücksichtigt werden. Im Gegensatz zu anderen Methoden benötigt die planungsbasierte Prädiktion keinerlei interpretative Anteile, wie z.B. die Unterscheidung zwischen verschiedenen Dynamikzuständen oder Verhaltensweisen, sondern löst diese implizit.

Durch den modularen Aufbau der Prädiktion lassen sich ohne weiteres weitere Informationen einbinden. So sind die Filtermasken der Prädiktion beliebig austauschbar, um weitere Bewegungsmodelle darzustellen. Auch könnten gar die Umgebungseinflüsse dynamisch verändert werden, um so auf zeitlich veränderliche Umstände wie z.B. andere dynamische Verkehrsteilnehmer eingehen zu können. Ebenso ließe sich das Umgewichten und Neuziehen der Ziele durch Umgebungs- oder Dynamikinformationen verfeinern.

Insgesamt zeigt die Prädiktion aber bereits eine hohe Güte deutlich über einfachen Dynamikmodellen, sodass ihre besondere Stärke gerade bei hohen Prädiktionszeiträumen liegt.

## Literatur

- [1] Y. Abramson and B. Steux. Hardware-friendly pedestrian detection and impact prediction. In *Intelligent Vehicles Symposium, 2004 IEEE*, pages 590–595, June 2004.

- [2] Z. Chen, D. C. K. Ngai, and N. H. C. Yung. Pedestrian behavior prediction based on motion patterns for vehicle-to-pedestrian collision avoidance. In *Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on*, pages 316–321, Oct 2008.
- [3] Z. Chen and N. H. C. Yung. Improved multi-level pedestrian behavior prediction based on matching with classified motion patterns. In *Intelligent Transportation Systems, 2009. ITSC '09. 12th International IEEE Conference on*, pages 1–6, Oct 2009.
- [4] S.-Y. Chung and H.-P. Huang. A mobile robot that understands pedestrian spatial behaviors. In *Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on*, pages 5861–5866, Oct 2010.
- [5] C. Keller and D. Gavrila. Will the pedestrian cross? a study on pedestrian path prediction. *Intelligent Transportation Systems, IEEE Transactions on*, 15(2):494–506, April 2014.
- [6] C. G. Keller, C. Hermes, and D. M. Gavrila. Will the pedestrian cross? probabilistic path prediction based on learned motion features. In *Pattern Recognition*, pages 386–395. Springer, 2011.
- [7] K. M. Kitani, B. D. Ziebart, J. A. Bagnell, and M. Hebert. Activity forecasting. In *Computer Vision—ECCV 2012*, pages 201–214. Springer, 2012.
- [8] H. Kloeden, D. Schwarz, R. H. Rasshofer, and E. M. Biebl. Fusion of cooperative localization data with dynamic object information using data communication for preventative vehicle safety applications. *Advances in Radio Science*, 11:67–73, 2013.
- [9] S. Kohler, M. Goldhammer, S. Bauer, K. Doll, U. Brunsmann, and K. Dietmayer. Early detection of the pedestrian’s intention to cross the street. In *Intelligent Transportation Systems (ITSC), 2012 15th International IEEE Conference on*, pages 1759–1764, Sept 2012.
- [10] R. Quintero, J. Almeida, D. Llorca, and M. Sotelo. Pedestrian path prediction using body language traits. In *Intelligent Vehicles Symposium Proceedings, 2014 IEEE*, pages 317–323, June 2014.
- [11] N. Schneider and D. M. Gavrila. Pedestrian path prediction with recursive bayesian filters: A comparative study. In *Pattern Recognition*, pages 174–183. Springer, 2013.
- [12] C. Wakim, S. Capperon, and J. Oksman. A markovian model of pedestrian behavior. In *Systems, Man and Cybernetics, 2004 IEEE International Conference on*, volume 4, pages 4028–4033 vol.4, Oct 2004.
- [13] B. Ziebart, N. Ratliff, G. Gallagher, C. Mertz, K. Peterson, J. Bagnell, M. Hebert, A. Dey, and S. Srinivasa. Planning-based prediction for pedestrians. In *Intelligent Robots and Systems, 2009. IROS 2009. IEEE/RSJ International Conference on*, pages 3931–3936, Oct 2009.