

Bedingte Verhaltensprädiktion interagierender Agenten

Florian Wirth*, Carlos Fernandez-Lopez* und Christoph Stiller*

Zusammenfassung: In der Literatur und in zahlreichen etablierten Benchmarks ist es üblich die zukünftige Position eines anderen Verkehrsteilnehmers (VT) anhand einer Vorhersageverteilung *pro Agenten* zu prädictieren und anhand der Grundwahrheit (GT) dieses Agenten zu evaluieren. Hierfür wird implizit entweder statistische Unabhängigkeit der zukünftigen Positionen der Agenten angenommen oder es wird davon ausgegangen, dass Randverteilungen für die Weiterverarbeitung von Prädiktionen genügen.

In diesem Beitrag wird vorgeschlagen paarweise multivariate Verteilungen als zusätzliche Ausgabe in Vorhersagemodelle für interagierende Agenten zu integrieren. Diese liefern mehr Information falls die Annahme statistischer Unabhängigkeit unzutreffend ist, und andernfalls gleich viel. Aus der paarweise multivariaten Verteilung können dann bedingte Verteilungen gegeben hypothetischer Positionen eines der beiden Agenten – bspw. des automatisierten Ego-Fahrzeugs – abgeleitet werden, wodurch die prädictierte Szene bzgl. verschiedener hypothetischer Aktionen und Aktionskombinationen analysiert werden kann. Der Vorschlag ist für viele Prädiktionsansätze einfach umsetzbar, wenn für jedes Agentenpaar in der Szene eine multivariate Verteilung generiert wird.¹

Schlüsselwörter: Verkehrsszenenprädiktion, bedingte Prädiktion, Verhaltensgenerierung

1 Einleitung

Solange (teil-)manuellgesteuerte Fahrzeuge und Fahrzeuge ohne V2V-Kommunikation im Straßenverkehr teilnehmen, die ihre geplante Trajektorie oder ihre Verhaltensabsicht nicht automatisiert mit anderen Verkehrsteilnehmern teilen können, benötigt ein automatisiertes Fahrzeug (AV) eine Form der Verhaltensvorhersage für die Absichten anderer VT, um sicheres Verhalten zu generieren bzw. eine Trajektorie zu planen. Verhalten zu prädictieren ist also kein Selbstzweck, sondern dient den nachgeschalteten Forschungsfeldern Verhaltensgenerierung und Trajektorienplanung.

Es stellt sich die Frage was eine Prädiktion leisten soll. Grundsätzlich möchte jeder VT schnell, komfortable, ressourcensparend und sicher ein Ziel erreichen. Um auf dem Weg zu diesen Zielen Positionskonflikte zwischen VT effizient zu lösen, interagieren VT unter Zuhilfenahme von Verkehrsregeln. Es bleiben oft mehrere Verhaltensoptionen, wodurch

*Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT) (E-Mail: florian.wirth@kit.edu).

¹Diese Arbeit basiert auf der Dissertation von Florian Wirth, die am 14.04.2023 bei der Fakultät für Maschinenbau des KIT eingereicht wurde. Details insb. bzgl. des konkreten Netzaufbaus aus dem erwähnten Anwendungsbeispiel in Abschnitt 3.1, der nicht im Fokus des vorliegenden Artikels steht, können dort nachgeschlagen werden.

Verhalten eines andere VT vom eigenen Verhalten abhängen kann oder umgekehrt. Häufig bedingen sich die Verhaltensoptionen zweier oder mehrerer VT gegenseitig und bilden Verhaltensmoden.

Daher genügt es oft nicht zu wissen wo ein anderer VT losgelöst von seinem Umfeld in ein paar Sekunden sein könnte. Eine bedingte Prädiktion erlaubt eine Analyse möglicher Szenenentwicklungen, die passendes Verhalten eines VTs gegeben eines bestimmten Verhaltens eines anderen VTs – bspw. des automatisierten Ego-Fahrzeugs² – liefert.

2 Stand der Technik

In der Literatur können verschiedene Formen der Modellausgabe gefunden werden, die hier aufgezählt und beschrieben werden.

Unabhängige Prädiktion von Agenten. Die meisten konkurrierenden Ansätze geben agentenzentrierte Positionsprädiktionen aus, die nicht zueinander in Bezug gesetzt werden können. Implizit wird Prädiktion hier als Zufallsexperiment modelliert, bei dem die zukünftigen Positionen mehrerer Agenten als statistisch unabhängig angenommen werden. Es kann daraus nicht abgeleitet werden welche Trajektorie von Agent *a* zu welcher Trajektorie von Agent *b* gehört [1, 2, 3, 4, 5, 6].

Obwohl auch sie agentenweise Positionsprädiktionen ausgeben, weisen Khandelwal and Qi *et al.* [7] auf die Notwendigkeit hin hypothetische Szenarienentwicklungen analysieren zu können und evaluieren ihr Prädiktionsmodell mit künstlich eingefügten Agenten, mit denen das Ego-Fahrzeug interagieren müsste, wenn sie tatsächlich existierten.

Ego-Trajektorie als Eingabe. Salzmann, Ivanovic *et al.* [8] fügen die geplante Trajektorie des Ego-Fahrzeugs in deren Modellinput hinzu. Dadurch hat das Modell die Möglichkeit Verhalten anderer Verkehrsteilnehmer bedingt auf verschiedene Ego-Trajektorien zu generieren. Auch Tolstaya *et al.* [9] schlagen ein Modell vor, das sie *Conditional Behavior Prediction* nennen und das von einem Agentenpaar ausgeht bestehend aus Mensch und Roboter, bei dem die Trajektorie des Roboters festgelegt wird und die zugehörige Trajektorie des Menschen prädictiert wird.

Konsistente Verhaltensmoden. In letzter Zeit geht der Trend hin zur Prädiktion konsistenter Verkehrsszenenentwicklungen, die *Moden (modes)* [10, 11] genannt werden. Eine Mode umfasst eine Trajektorie pro prädictiertem Agenten und wenn jeder Agent diese Trajektorie fährt entwickelt sich die Verkehrsszene unfallfrei. Im Allgemeinen gibt es für eine Verkehrsszene mehrere mögliche Moden.

Gilles *et al.* [12] schlagen ein Modell vor, das eine Belegtheitsrasterkarte für jeden Agenten generiert, woraus eine konstante Zahl von Trajektorienendpunkten gezogen wird. Ein nachgeschaltetes Modell lernt aus diesen Endpunkten konsistente Verhaltensmoden zu generieren und jeder Mode eine Auftrittswahrscheinlichkeit zuzuordnen.

Bedingte Prädiktion. Rhinehart *et al.* [13] erheben den Anspruch das erste bedingte Vorhersagemodell für das automatische Fahren entwickelt zu haben. Sie entwickelten ein generatives Modell für einzelne Agenten basierend auf Rhinehart *et al.* [14], das das Verhalten mehrerer Agenten prädictiert, gegeben ihre früheren Trajektorien und einer Rasterkarte. Das tun sie, indem sie das Verhalten aller Agenten mit einem gemeinsamen gene-

²Die gängige Abkürzung “AV” für *autonomous vehicle* wird im Folgenden synonym zum automatisierten Ego-Fahrzeug verwendet.

rativen Modell präzisieren, dessen Eingabe nicht nur die vergangene Trajektorie und die Rasterkarte ist, sondern auch ein Zufallszustand einer Gauß-Verteilung für jeden Agenten.

Wenn die Zuständen, die die gewünschte zukünftige Trajektorie des Roboters repräsentieren, gefunden werden, können die Zustände aller anderen Agenten mit Gauß'schem Rauschen gefüllt werden, während die Modelleingabe für den Roboter mit dem gefundenen Zustand ersetzt wird. Die Autoren formulieren ein Optimierungsproblem, mit dem der gewünschte Zustand für den Roboter generiert werden kann.

Tang *et al.* [15] veröffentlichen ein generatives Modell, das in der Lage ist verschiedene zukünftige Trajektorien *auszurollen* bei beliebig vielen vorgegebenen Wunschtrajektorien. Ein gemeinsames rekurrentes neuronales Netz für alle Agenten generiert zukünftige Positionen für den jeweils nächsten Zeitschritt. Da die Ausgabeposition wieder in das Modell eingespeist wird, kann diese Position für beliebig viele Agenten auf einen vorgegebenen Wert gesetzt werden.

Eine Erweiterung von Casas, Culino, Suo *et al.* [10] wird in Cui, Casas, Sadet *et al.* [16] vorgeschlagen, die direkt konsistente Verhaltensmoden ähnlich zu Gilles *et al.* [12] ziehen, und darüber hinaus eine Planungsmethode vorschlagen, die die generierte Ausgabe weiterverarbeiten kann.

Der Ansatz von Ngiam, Caine *et al.* [17] ist in der Lage eine beliebige Menge bedingter Trajektorienpunkte zu verarbeiten und gibt ebenfalls dazu konsistente Verhaltensmoden mit entsprechenden Wahrscheinlichkeiten aus.

3 Vorgeschlagene Prädiktionsausgabe

Aufgrund der Auswahl an Metriken in populären Benchmarks fokussieren sich viele Forscher auf die Positionsprädiktion einzelner Agenten. Häufig wird pro Agent eine Gauß'sche Mischung ausgegeben.

Im Gegensatz dazu wird vorgeschlagen Agenten paarweise zu präzisieren. Statt 2D Gauß-Mischverteilungen können 4D Gauß-Mischverteilungen generiert werden. Diese stehen nun für paarweise Verhaltensmoden zweier Agenten und können entsprechend trainiert und analysiert werden.

Üblicherweise werden innerhalb von Prädiktionsmodellen zukünftige latente Zustände einzelner Agenten $\mathbf{s}_a \forall a \in [1, \dots, n_A]$ trainiert, aus denen dann die Modellausgabe für diesen Agenten decodiert wird. Hierbei ist n_A die Anzahl der Agenten in der Szene. Stattdessen kann durch Kreuzung dieser Zustände eine Informationsrepräsentation $[\mathbf{s}_a, \mathbf{s}_b] \forall (a, b) \in [1, \dots, n_A]^2$ geschaffen werden, die die Zustände zweier Agenten enthält. Nun kann ein – üblicherweise trainierbarer – Decoder φ_{Decod} entworfen werden, der die 4D Ausgabe anhand der veränderlichen Gewichte im Decoder optimiert gegeben der Zustandspaare $[\mathbf{s}_a, \mathbf{s}_b]$. Da Symmetrie der 4D-Verteilung bezüglich des Agentenpaares $\varphi_{\text{Decod}}([\mathbf{s}_a, \mathbf{s}_b]) \stackrel{!}{=} \varphi_{\text{Decod}}([\mathbf{s}_b, \mathbf{s}_a])$ erwartet wird, kann die Eingabe des Decoders z.B. zu $\varphi_{\text{Decod}}(\mathbf{s}_b + \mathbf{s}_a)$ gewählt werden. Somit ist die Ausgabe des Decoders invariant gegenüber der Reihenfolge von a und b .




Abbildung 1: Visualisierung der Graphmodellierung: Der Kartengraph ist zerteilt in Fahrbahnstücke, die in etwa die Fläche einnehmen, die ein Auto belegt. Die Position eines Agenten wird festgelegt durch eine diskrete Verteilung über alle Fahrbahnstücke. In dieser Grafik hat die Verteilung jedes Agenten genau einen Eintrag, der eine 1 enthält. Dieser weist dem Agenten genau ein Fahrbahnstück zu.

3.1 Anwendungsbeispiel: Diskrete Prädiktion von Agenten auf einem Kartengraphen

Multivariate Wahrscheinlichkeiten können besonders einfach generiert werden, wenn die Karte als Graph mit diskreten Aufenthaltswahrscheinlichkeiten aufgefasst wird. In Abb. 1 ist ein Kartengraph dargestellt, der aus Fahrstreifenstücken $l \in [1, \dots, n_L]$ besteht, die ungefähr die Größe eines Autos einnehmen. Hierbei ist n_L die Anzahl der Fahrstreifenstücke in der betrachteten Szene. Somit entspricht die maximale Positionsgenauigkeit für einen Agenten der Größe des Agenten, was als ausreichend angenommen wird. Weiterhin wird die aktuelle Position jedes Agenten im Kartengraph bestimmt und zur Prädiktion über n_T diskrete, zukünftige Zeitschritte t werden Zustände der Agenten entlang des Kartengraphen propagiert. Es liegt also im Kartengraph für jeden Agenten a auf jedem Fahrstreifenstück l zu jedem zukünftigen Zeitschritt $t \in [1, \dots, n_T]$ ein latenter, trainierbarer Zustand $\mathbf{s}_{t,l,a}$ vor.

Aus diesem Zustand kann nun wie gehabt eine Aufenthaltswahrscheinlichkeit $p_{t,l,a} = \text{norm}_l(\varphi_{\text{Decod}}(\mathbf{s}_{t,l,a}))$ generiert werden, indem durch Normalisierung über die Fahrstreifenstücke sichergestellt ist, dass die Ausgabe Anforderungen an eine Wahrscheinlichkeitsverteilung genügt. Dies entspricht der Wahrscheinlichkeit $\mathcal{P}$ des Ereignisses Ω , dass sich Agent a zum Zeitpunkt t auf Fahrstreifenstück l befinden wird: $p_{t,l,a} = \mathcal{P}(\Omega_{t,l,a})$. Dem Vorschlag dieses Artikels folgend kann darüber hinaus eine bivariate, diskrete Verteilung für jedes Agentenpaar generiert werden:

$$p_{t,k,b,l,a} = p_{t,l,a,k,b} = \text{norm}_{l,k}(\varphi_{\text{Decod}}(\mathbf{s}_{t,l,a} + \mathbf{s}_{t,k,b})) = \mathcal{P}(\Omega_{t,l,a} \wedge \Omega_{t,k,b}). \quad (1)$$

Die Indizes k, b stehen hierbei für den zweiten Agenten b auf dem Fahrstreifenstück k . Durch Wählen konkreter Werte für b und k (oder a und b) und normalisieren über den jeweils anderen Fahrstreifenstückindex l (oder k) kann eine diskrete bedingte Prädiktion generiert werden für einen Agenten gegeben einer zukünftigen Position eines anderen Agenten. Analog kann über Bereiche einer kontinuierlichen Verteilung integriert und normalisiert werden.

3.2 Analysemöglichkeiten anhand bedingter Vorhersagen

Anhand der Trainingsdaten liefert das Modell das wahrscheinlichste menschliche Verhalten für die vorliegende Verkehrssituation, sofern – wie die meisten heutigen Datensätzen –




Abbildung 2: Visualisierung der Prädiktion zweier Agenten. Die bedingte Prädiktion wird durch Verbindungslinien in der Farbe des bedingten Agenten (blau) visualisiert. Die Farbintensität repräsentiert hierbei die Wahrscheinlichkeit. Als Bedingung wird das GT Fahrstreifenstück (rot umrandet) des aktuell prädierte Agent verwendet (magenta). Die bedingte Positionsprädiktion für den blauen Agenten gegeben, dass der rote Agent in den Kreisverkehr eingefahren ist, zeigt vorrangig auf eines der Fahrstreifenstücke, die zum ersten Ausgang des Kreisverkehrs gehören.



ausschließlich manuell gesteuerte Fahrzeug aufgenommen wurden. Es wird daher empfohlen bedingte Prädiktionen für das AV gegeben der wahrscheinlichsten Position desjenigen Agenten zu generieren, mit dem das AV den größten zukünftigen Positionskonflikt hat. Anhand dieser bedingten Prädiktion kann das AV ein Verhalten oder eine Trajektorie generieren, die menschlichem Fahrverhalten nahekommt. Positionskonflikte können anhand der Überlappung naiver Positionsprädiktionsmethoden bspw. anhand von 1D Kalman-Filtern mit einem konstante-Beschleunigung-Modell entlang der Fahrstreifen generiert werden. Da häufig nur ein Positionskonflikt mit einem anderen Agenten vorliegt, genügt eine paarweise Analyse der Prädiktion von Agenten oft, um Verhalten für kurze Planungshorizonte von wenigen Sekunden zu generieren. Wenn die paarweise Analyse mehrerer anderer Fahrzeuge bzgl. des AV vergleichbares Verhalten für das AV ergeben, wird die paarweise Betrachtung ebenfalls als ausreichend angesehen.

Allerdings sind Beispiele denkbar, bei denen Konflikte nicht nur paarweise auftreten, sondern die gerichtete Kausalkette drei oder mehr Agenten umfassen. Statistische Modelle liefern nur statistische Zusammenhänge, nicht jedoch die Richtung der Kausalbeziehung. Für mehr als zwei Agenten a, b, c , bspw. in einem Rechts-vor-Links-Szenario bei der *kein* Deadlock entsteht, kann überprüft werden, ob das Verhalten für a aus den Paaren (a, b) und (b, c) mit dem Verhalten aus (a, c) übereinstimmt. Der Vorschlag dieses Artikels multivariate Verteilungen für Agentenpaare zu generieren enthält im Gegensatz zu Arbeiten, die konsistente Verhaltensmoden generieren, keinen Mechanismus, der einen solchen statistischen Ringschluss sicherstellt. Der Ringschluss kann also beim vorliegenden Vorschlag dazu verwendet werden, um die Kohärenz von mehr als zwei bedingten Prädiktionen zu überprüfen. Sollte sich der Ringschluss als grob unzulässig erweisen, ist die Prädiktion mit Vorsicht zu behandeln. Die Verkehrssituation muss sich dann ggf. erst mit konservativem Verhalten des AVs weiterentwickeln, um zu einem validen Prädiktionsergebnis zu führen.


4 Beispiele für die Situationsanalyse

In Abb. 2 wird an einem Beispiel aus dem INTERACTION Datensatz die verwendete Visualisierung für die diskrete Positionsprädiktion und die diskrete bedingte Prädiktion in Kürze erläutert.


Der Eingang des Modells – die aktuellen Beobachtungen der Agenten – sind als far-



- (a) Die Prädiktionen von Agent #30 (rot) und #31 (grün unten) passen nach 2.1 s gut zur GT. Auch die bedingten Prädiktionen zeigen von der GT zu den Fahrbahnstücken, auf denen der jeweils andere Agent in der Zukunft ist.





- (b) Auch nach 3.3s zeigen die farbigen Linien zu den farbigen Boxen des jeweils anderen Agenten.





- (c) Für 4.5s macht die große Unsicherheit in longitudinaler Richtung zwischen den Verhaltensoptionen "Bremsen" und "Einfahren" von Agent #31 die Prädiktion weitestgehend unbrauchbar. Die bedingten Prädiktionen passen jedoch für beide Agenten weiterhin gut zur GT des jeweils anderen Agenten.

Abbildung 3: Bedingte Prädiktion, Beispiel 1: roundD-Datensatz, location1.



biges Rechtecke mit schwarzer Agenten-ID dargestellt, die zugehörige zukünftige Position als transparente Rechtecke mit farbigem Rahmen. Die Straßentopologie wird in grau angedeutet, es handelt sich um einen Kreisverkehr. Die prädiizierte Belegtheitswahrschein-




- (a) Links: 0.3 s. Rechts: 1.2 s. Ein Reißverschlusszenario, in welchem der lila Agent #15 vor und der grüne Agent #17 vor dem braunen Agenten #16 einfädelt.





- (b) Links: 2.1 s. Rechts: 3.3 s. Die bedingte Prädiktion dargestellt anhand von lila und grünen Linien geben die Reihenfolge des Einfädelns für kurze und lange Prädiktionshorizonte korrekt an.



- (c) 0.3 s: Einige Sekunden später fahren der pinke Agent #22 und der dunkelgrüne Agent #21 direkt nebeneinander in die Szene ein. Bereits für kurze Prädiktionshorizonte...




- (d) 0.6 s: ...wird die Einfädelreihenfolge korrekt prädiziert,...




- (e) 0.9 s: ...die vermutlich aus der Geschwindigkeitsdifferenz beider Agenten abgeleitet wurde: Der pinke Agent hat bereits nach der ersten Sekunde eine größere Strecke zurückgelegt, daher wird er bereits nach kurzer Zeit als vor Agent #21 einfädelnd prädiziert.

Abbildung 4: Bedingte Prädiktion, Beispiel 2: INTERACTION-Datensatz, DR_DEU_Merging_MT. Zwei Fahrstreifen verengen zu einer. (a) und (b) zeigen vier verschiedene Prädiktionshorizonte einer ersten Reißverschlusszene. (c), (d) und (e) zeigen zwei Agenten #21 und #22 zu drei verschiedenen Prädiktionshorizonten einer zweiten Reißverschlusszene. In allen gezeigten Beispielen deutet die bedingte Prädiktion mittels farblicher Linien die tatsächlich gefahrene Einfädelordnung korrekt an.



lichkeit wird durch Einfärbung der entsprechenden Fahrstreifenstücke mit der Farbe des zugehörigen Agenten dargestellt (hier magenta für Agent #30). Deren Farbintensität repräsentiert die Wahrscheinlichkeit. Das GT-Fahrbahnstück ist rot umrandet. Die bedingte Prädiktion gegeben des GT-Fahrbahnstücks (rot) des aktuell prädizierten Agenten (magenta) wird durch farbige Linien (blau) visualisiert, die zu den wahrscheinlichen, zugehörigen Fahrbahnstreifen desjenigen Agenten zeigen, dessen Farbe die Linien haben.



- (a) Der lila Agent #12 fährt in den Kreisverkehr und wird mit je ca. 50% wird er den Kreisverkehr an der ersten Ausfahrt verlassen oder darin bleiben. Die wahrscheinlichste Positionsprädiktion für das graue Fahrzeug #3 bedingt darauf, dass Agent #12 im Kreisverkehr bleibt, liegt bei der Stoplinie der Zufahrt: Dies wird durch die graue Linie vom roten GT-Fahrstreifenabschnitt von #12 hin zur Stoplinie der Zufahrt veranschaulicht.



- (b) Umgekehrt wird die bedingte Wahrscheinlichkeit für #12 dargestellt gegeben, dass #3 vor der Stoplinie bremst. Links, 2.1 s: Anfangs ist die Wahrscheinlichkeitsmasse der bedingten Prädiktion mehr oder weniger gleichverteilt zwischen den zwei Verhaltensoptionen von #12 *im Kreisverkehr bleiben* und *die erste Ausfahrt nehmen*. Rechts, 3.3 s: Da #3 bremsen muss, um hinter der Stoplinie zu bleiben und #12 vorbeifahren zu lassen, zeigen die lila Linien nun nur noch in den Kreis des Kreisverkehrs, wodurch die zwei korrespondierenden Verhaltensmoden von #3 und #12 verbunden werden.



- (c) Im Gegensatz dazu verlässt der braune Agent #7 den Kreisverkehr und der grüne Agent #12 kann direkt einfahren. Während die bedingte Prädiktion für #7 gegeben des Einfahrens von #12 gut passt (links, 3.9 s), scheint die bedingte Prädiktion für #12 gegeben, dass #7 den Kreisverkehr verlässt, mehrdeutig (rechts, 3.9 s). Dies könnte von der asymmetrischen Abhängigkeit herrühren: Das Verhalten von #12 hängt von Agent #7 ab, da #12 Vorfahrt gewährend müsste, aber auch von jedem Agenten hinter #7. Agent #7 kann sich unabhängig von #12 bewegen, da er Vorfahrt hat, und unabhängig von jedem Agenten hinter ihm selbst.

Abbildung 5: Beispiel 3: INTERACTION-Datensatz, DR_DEU_Roundabout_OF. Eine dichte Verkehrsszene an einem Kreisverkehr ist abgebildet für verschiedene Agenten und verschiedene Prädiktionshorizonte.

Das zugehörige Verhalten des blauen Agenten #29 gegeben, dass der Agent in magenta #30 in den Kreisverkehr einfährt (rot umrandetes Fahrstreifenstück), ist also ein Verlassen des Kreisverkehrs über die erste Ausfahrt. Die Kausalität aber ist in diesem Beispiel umgekehrt: *Weil* der blaue Agent – der Vorfahrt hätte – die erste Ausfahrt nimmt, fährt der Agent in magenta direkt in den Kreisverkehr.

In Abb. 3, Abb. 4 und Abb. 5 werden anhand dreier Beispiele die Vorzüge und Eigenschaften bedingter Prädiktionen erläutert.

5 Schlussfolgerung

Bedingte Positionsprädiktionen liefern einen deutlichen Mehrwert gegenüber reinen Positionsprädiktionen, bei denen implizit statistische Unabhängigkeit der zukünftigen Positionen von Agenten angenommen wird. In diesem Beitrag wird eine Methode vorgeschlagen, mit der sich bedingte Prädiktionen in viele Prädiktionsverfahren einfach integrieren lassen. Der Vorschlag umfasst die Prädiktion von multivariaten Verteilungen für jedes Agentenpaar einer Verkehrsszene, aus der bedingte Prädiktionen abgeleitet werden können. Hiermit kann eine Vielzahl hypothetischer Entwicklungen einer Verkehrsszene analysiert und für die Verhaltensgenerierung oder die Trajektorienplanung verwendet werden.

Literatur

- [1] W. Zeng, M. Liang, R. Liao, and R. Urtasun, “Lanercnn: Distributed representations for graph-centric motion forecasting,” *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 532–539, 2021.
- [2] T. Gilles, S. Sabatini, D. Tsishkou, B. Stanciulescu, and F. Moutarde, “Home: Heat-map output for future motion estimation,” in *IEEE International Intelligent Transportation Systems Conference (ITSC)*, (Indianapolis, IN, USA), pp. 500–507, 2021.
- [3] M. Ye, T. Cao, and Q. Chen, “Tpcn: Temporal point cloud networks for motion forecasting,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (Nashville, TN, USA), pp. 11318–11327, 2021.
- [4] Y. Yuan, X. Weng, Y. Ou, and K. M. Kitani, “Agentformer: Agent-aware transformers for socio-temporal multi-agent forecasting,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, (Montreal, Canada), pp. 9813–9823, October 2021.
- [5] T. Gilles, S. Sabatini, D. Tsishkou, B. Stanciulescu, and F. Moutarde, “Gohome: Graph-oriented heatmap output for future motion estimation,” in *International Conference on Robotics and Automation (ICRA)*, (Philadelphia, PA, USA), pp. 9107–9114, 2022.
- [6] B. Varadarajan, A. Hefny, A. Srivastava, K. S. Refaat, N. Nayakanti, A. Cornman, K. Chen, B. Douillard, C. P. Lam, D. Anguelov, *et al.*, “Multipath++: Efficient information fusion and trajectory aggregation for behavior prediction,” in *International Conference on Robotics and Automation (ICRA)*, (Philadelphia, PA, USA), pp. 7814–7821, 2022.

- [7] S. Khandelwal, W. Qi, J. Singh, A. Hartnett, and D. Ramanan, “What-if motion prediction for autonomous driving,” *CoRR*, vol. abs/2008.10587, 2020.
- [8] T. Salzmann, B. Ivanovic, P. Chakravarty, and M. Pavone, “Trajectron++: Dynamically-feasible trajectory forecasting with heterogeneous data,” in *European Conference on Computer Vision (ECCV)*, (Glasgow, United Kingdom), pp. 683–700, Springer, 2020.
- [9] E. Tolstaya, R. Mahjourian, C. Downey, B. Vadarajan, B. Sapp, and D. Anguelov, “Identifying driver interactions via conditional behavior prediction,” in *2021 IEEE International Conference on Robotics and Automation (ICRA)*, (Xi’an, China), pp. 3473–3479, 2021.
- [10] S. Casas, C. Gulino, S. Suo, K. Luo, R. Liao, and R. Urtasun, “Implicit latent variable model for scene-consistent motion forecasting,” in *European Conference on Computer Vision (ECCV)*, (virtual), pp. 624–641, Springer, 2020.
- [11] S. H. Park, G. Lee, J. Seo, M. Bhat, M. Kang, J. Francis, A. Jadhav, P. P. Liang, and L.-P. Morency, “Diverse and admissible trajectory forecasting through multimodal context understanding,” in *European Conference on Computer Vision (ECCV)*, (Glasgow, United Kingdom), pp. 282–298, Springer, 2020.
- [12] T. Gilles, S. Sabatini, D. Tsishkou, B. Stanciulescu, and F. Moutarde, “Thomas: Trajectory heatmap output with learned multi-agent sampling,” in *International Conference on Learning Representations (ICLR)*, (virtual), 2022.
- [13] N. Rhinehart, R. McAllister, K. Kitani, and S. Levine, “Precog: Prediction conditioned on goals in visual multi-agent settings,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, (Seoul, Korea), October 2019.
- [14] N. Rhinehart, K. M. Kitani, and P. Vernaza, “R2p2: A reparameterized pushforward policy for diverse, precise generative path forecasting,” in *Proceedings of the European Conference on Computer Vision (ECCV)*, (Munich, Germany), pp. 772–788, 2018.
- [15] C. Tang and R. R. Salakhutdinov, “Multiple futures prediction,” *Advances in Neural Information Processing Systems*, vol. 32, 2019.
- [16] A. Cui, S. Casas, A. Sadat, R. Liao, and R. Urtasun, “Lookout: Diverse multi-future prediction and planning for self-driving,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, (Montreal, Canada), pp. 16107–16116, October 2021.
- [17] J. Ngiam, V. Vasudevan, B. Caine, Z. Zhang, H.-T. L. Chiang, J. Ling, R. Roelofs, A. Bewley, C. Liu, A. Venugopal, D. J. Weiss, B. Sapp, Z. Chen, and J. Shlens, “Scene transformer: A unified architecture for predicting future trajectories of multiple agents,” in *International Conference on Learning Representations (ICLR)*, (virtual), 2022.