

# Soziale Verhaltensprädiktion für automatisierte Fahrzeuge durch Contrastive Learning

## Social Behavior Prediction for Automated Vehicles Using Contrastive Learning

Timo Osterburg\*, timo.osterburg@tu-dortmund.de

Christopher Diehl\*, christopher.diehl@tu-dortmund.de

Univ.-Prof. Dr.-Ing. Prof. h.c. Dr. h.c. Torsten Bertram\*, torsten.bertram@tu-dortmund.de

\* Technische Universität Dortmund, Lehrstuhl für Regelungssystemtechnik, 44227 Dortmund, Deutschland

### Kurzfassung

Die zeitliche Vorhersage der aktuellen Umgebungssituation spielt bei automatisierten Fahrzeugen eine wichtige Rolle, um eine sichere Bewegungsplanung durchzuführen [1]. In den vergangenen Jahren haben sich *Deep Learning* basierte Lösungsverfahren für das Problem der Szenenprädiktion durchgesetzt. In der Regel enthalten die für das Training verwendeten Datensätze nur Szenen von menschlichem Verhalten in sicheren Bereichen. Das neuronale Netz wird trainiert, diese *positiven* Beispiele so gut wie möglich zu reproduzieren. Menschliche Fahrer hingegen führen auf Grundlage der verfügbaren Daten Gedankenexperimente durch und versuchen *negative* Entwicklungen besonders zu verhindern, während sie eine optimale Entwicklung anstreben. So werden beispielsweise Kollisionen stets und unter allen Umständen vermieden. Durch die Demonstration von rein positiven Beispielen, ist es Lernalgorithmen aber schwer möglich zu erfassen, welche negativen Entwicklungen der Szene besonders abzuwenden sind. Dies führt in der Anwendung, insbesondere in wichtigen Szenarien, die außerhalb der Trainingsverteilung liegen, zu Fehlverhalten des automatisierten Fahrzeugs.

Verfahren des *Contrastive Learnings* lösen dieses Problem durch eine Verlustfunktion, welche sowohl positive als auch negative Beispiele berücksichtigt [2]. Die Autoren von [3] wenden dieses Verfahren auf die Prädiktion von Fußgängern an. Hierbei wird ein Samplingverfahren vorgeschlagen, welches Negativbeispiele aus sozialen Interaktionen generiert. Die vorgeschlagene Verlustfunktion wird daher als *Social-Noise-Contrastive Estimation* (SNCE) bezeichnet. Die Annahme ist hierbei, dass Fußgänger Kollisionen vermeiden und einen komfortablen Abstand zu einander einhalten. Die Arbeiten von [3] finden in der Literatur vorwiegend Anwendung in der Vorhersage von Fußgängertrajektorien, während verwandte Prädiktionsprobleme bislang kaum betrachtet werden.

In diesem Beitrag wird die Anwendung der SNCE-Verlustfunktion auf die Vorhersage von Fahrzeugtrajektorien aus dem *Argoverse I* (Argo)-Datensatz [4] betrachtet. Das verwendete neuronale Netz ist in **Bild 1** schematisch dargestellt. Die Implementierung folgt dem in [5] verwendeten Basisnetz. Das Prädiktionsnetz ist während des Trainings um einen Zweig für das *Contrastive Learning* erweitert. Aus den Daten werden positive und negative Beispiele extrahiert und durch ihre Position  $\mathbf{s}_t^k = [x_t^k, y_t^k]$ , mit longitudinaler ( $x_t^k$ ) und lateraler ( $y_t^k$ ) Position bezüglich des Ego-Fahrzeugkoordinatensystems zum diskreten Zeitpunkt  $t$  für jeden Verkehrsteilnehmer  $k$ , beschrieben. Der lernbare Beispielenkoderer  $\phi(\mathbf{s}_{T+\delta t}^k, \delta t)$  überführt die zum Prädiktionszeitpunkt  $T$  zukünftigen Zustände an diskreten Zeitpunkten  $T + \delta t$  auf dem Prädiktionshorizont  $N_p$  zeitabhängig in eine latente Repräsentation. Eine weitere lernbare Funktion  $\psi(\mathbf{h}_a^0)$  überführt die latente Beschreibung des Ego-Fahrzeugs  $\mathbf{h}_a^0$  vor dem Trajektorienkodierer in denselben latenten Raum wie die negativen und positiven Beispiele. Die mit gaußischem Rauschen  $\mathbf{n}$  überlagerten zukünftigen Positionen der anderen Verkehrsteilnehmer bilden die negativen und die verrauschten eigenen zukünftigen Positionen die positiven Beispiele. Das Rauschen verhindert hierbei eine Überanpassung der lernbaren Funktionen  $\phi$  und  $\psi$ . Für das Training wird die SNCE-Verlustfunktion

$$\mathcal{L}_{\text{SNCE}} = -\log \sum_{\delta t=1}^{N_p} \frac{\exp(\psi(\mathbf{h}_a^0) \cdot \phi(\mathbf{s}_{T+\delta t}^0 + \mathbf{n}, \delta t) / \tau)}{\sum_{k=1}^A \exp(\psi(\mathbf{h}_a^0) \cdot \phi(\mathbf{s}_{T+\delta t}^k + \mathbf{n}, \delta t) / \tau)} \quad (1)$$

als Hilfverlust verwendet, um die latente Beschreibung des Ego-Fahrzeugs  $\mathbf{h}_a^0$  möglichst distinktiv zu den negativen und möglichst identisch zu den positiven Beispielen abzubilden. Die endgültige Verlustfunktion für das Training setzt sich aus einer gewichteten Addition des L2-Verlusts für die Trajektorienprädiktion und dem SNCE-Verlust zusammen:  $\mathcal{L} = \mathcal{L}_{\text{L2}} + \lambda \mathcal{L}_{\text{SNCE}}$ . Durch die Rückpropagation der Ableitung des Verlusts durch die Abbildungsfunktion wird bereits der Enkodierer lernen, möglichst distinktive, latente Variablen für das Ego-Fahrzeug zu berechnen. Während der Inferenz wird nur noch der Netzpart für die Prädiktion verwendet, sodass keine Erhöhung des Rechenaufwands bei der Anwendung stattfindet. Dies ermöglicht ebenfalls einen fairen Vergleich der Prädiktionsgüte, da beide Modelle dieselbe Netzstruktur und Anzahl an Parametern aufweisen.

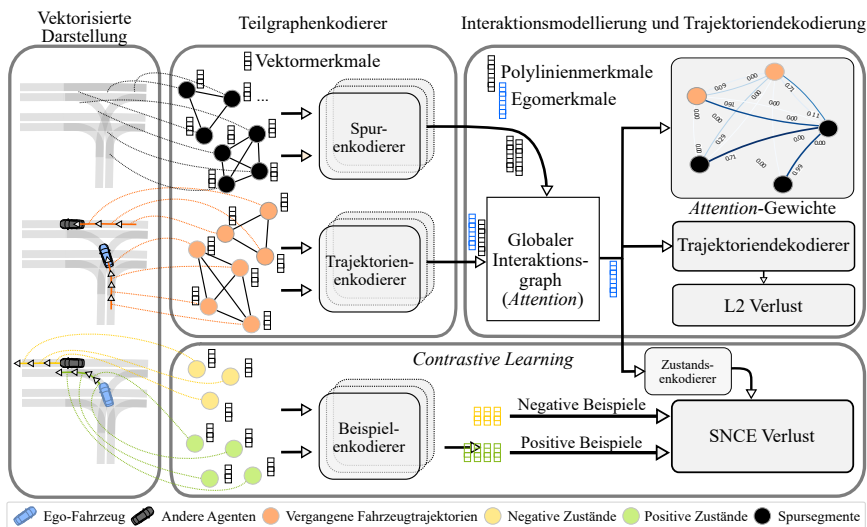
Zur Untersuchung der Auswirkungen auf die Distanz zu anderen Verkehrsteilnehmern wird die Pseudo-Kollisionsrate über alle  $N_S$  Evaluationsbeispiele berechnet:  $R_{\text{col}} = \sum_{n=0}^{N_S-1} \mathbf{I}(\mathbf{d} \leq d_{\text{crit}}) / N_S$ , wobei  $\mathbf{I}(\mathbf{d} \leq d_{\text{crit}}) = 1$ , falls eine Distanz  $d$  in

Diese Forschung wurde im Rahmen des Projektes KISSaF durch das Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestages gefördert.

DOI: 10.17185/dupublico/77390




Dieses Werk ist lizenziert unter einer Creative Commons Namensnennung 4.0 International Lizenz.



**Bild 1** Schematische Darstellung des für die Trajektorienprädiktion verwendeten neuronalen Netzes. Der *Contrastive Learning*-Block ist dabei nur während des Trainings aktiv.

**Tabelle 1** Quantitative Gegenüberstellung des Modells mit und ohne SNCE-Hilfverlust mittels ADE, FDE und Pseudo-Kollisionsrate  $R_{col}$ . Fette Einträge markieren das beste Ergebnis.

Verlustfunktion	ADE [m]	FDE [m]	$R_{col}$ [%]
L2	1.596	3.624	6.422
<b>L2 + S-NCE</b>	<b>1.505</b>	<b>3.355</b>	<b>5.885</b>



**Bild 2** Qualitative Prädiktionsergebnisse des ohne (links) und mit (rechts) Social-NCE-Hilfverlust trainierten Modells.

den Distanzen  $d$  aller Verkehrsteilnehmer zum Ego-Fahrzeug zu jedem Prädiktionszeitpunkt kleiner gleich  $d_{crit}$  ist und 0 sonst. Da der Argo-Datensatz keine Ausmaße der Objekte beinhaltet, werden alle Verkehrsteilnehmer die sich innerhalb eines Kreises mit Radius  $d_{crit} = 2.5\text{m}$  um das Ego-Fahrzeug befinden als Pseudo-Kollision betrachtet. Die Pseudo-Kollisionsrate ist somit ein approximatives Maß für den eingehaltenen Abstand zu allen anderen Verkehrsteilnehmern.

Die Verwendung des SNCE-Hilfverlusts führt zu einer Reduktion der Pseudo-Kollisionsrate sowie der für die Trajektorienprädiktion gängigen Metriken *average displacement error* (ADE) und *final displacement error* (FDE) (**Tabelle 1**). Somit sorgt der Hilfverlust nicht nur für einen höheren Abstand zu anderen Verkehrsteilnehmern, sondern führt ebenfalls zu einer verbesserten Abbildung des menschlichen Fahrverhaltens in der Vorhersage. **Bild 2** zeigt ein qualitatives Prädiktionsbeispiel beider Modelle. Während ohne SNCE-Hilfverlust eine sicherheitskritische Prädiktion in den Gegenverkehr erfolgt, verlässt die Vorhersage des mit Hilfverlusts trainierten Netzes nicht die eigene Spur.

Mithilfe des *Contrastive Learnings* ist es möglich, Domänenwissen in Form von positiven und negativen Beispielen in den Trainingsprozess zu integrieren. Dabei ist eine Vorhersage der seltenen, aber wichtigen negativen Entwicklungen einer Szene weiterhin möglich, da sie nicht explizit ausgeschlossen werden. In zukünftigen Arbeiten soll das Samplingverfahren für positive und negative Zustände erweitert werden, um Karteninformationen der Umgebung stärker in die Trajektorienprädiktion einfließen zu lassen. So ist es beispielsweise denkbar, kollisionsfreie Positionen auf Spurmitten als positive Beispiele und das Überqueren durchgezogener Spurmarkierungen als negative Beispiele zu verwenden.

## Literatur

- [1] Diehl, C.; et al.: *UMBRELLA: Uncertainty-Aware Model-Based Offline Reinforcement Learning Leveraging Planning*. In: arXiv preprint. 2021. arXiv:2111.11097.
- [2] Oord, A. V. D.; Li, Y.; Vinyals, O.: *Representation learning with contrastive predictive coding*. In: arXiv preprint. 2018. arXiv:1807.03748.
- [3] Liu, Y.; Yan, Q.; Alahi, A.: *Social nce: Contrastive learning of socially-aware motion representations*. In: Proceedings of the IEEE/CVF Internationale Conference on Computer Vision. 2021. S. 15119-15129.
- [4] Chang, M. F.; et al.: *Argoverse: 3d tracking and forecasting with rich maps*. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019. S. 8748-8757.
- [5] Diehl, C.; et al.: *Conditional Behavior Prediction for Automated Driving on Highways*. In: Proceedings of the 32. Workshop Computational Intelligence. 2022 (accepted).

# DuEPublico

Duisburg-Essen Publications online

UNIVERSITÄT  
DUISBURG  
ESSEN

*Offen im Denken*

ub | universitäts  
bibliothek

In: Neunte IFToMM D-A-CH Konferenz 2023

Dieser Text wird via DuEPublico, dem Dokumenten- und Publikationsserver der Universität Duisburg-Essen, zur Verfügung gestellt. Die hier veröffentlichte Version der E-Publikation kann von einer eventuell ebenfalls veröffentlichten Verlagsversion abweichen.

**DOI:** 10.17185/duepublico/77390

**URN:** urn:nbn:de:hbz:465-20230314-151851-5



Dieses Werk kann unter einer Creative Commons Namensnennung 4.0 Lizenz (CC BY 4.0) genutzt werden.