

PLATTFORM ZUM AUSTAUSCH VON MOBILITÄTSDATEN

FORSCHUNGSINTERESSE:

- Wie können Mobilitätsdaten datenschutzgerecht und sicher zwischen verschiedenen Akteuren ausgetauscht werden?
- Wie kann eine transparente Datenverarbeitung erfolgen?

VORGEHEN:

- Die Wissenschaftler*innen untersuchten Techniken, um Mobilitätsdaten effizient und sicher über eine Datenplattform auszutauschen. Der Datenaustausch zwischen verschiedenen Akteuren (z. B. Automobilhersteller, Kommunen) kann dazu beitragen, Mobilitätsdienstleistungen und -produkte zu verbessern.
- In Gesprächen mit Praxispartnern (z. B. größere Automobilhersteller, Unternehmensberatungen, Start Ups für neuartige Mobilitäts-Services) und im Rahmen von Literaturrecherchen ermittelten die Wissenschaftler*innen Anwendungsfälle, die besonders vom Datenaustausch in solchen Datenallianzen profitieren würden.

ERGEBNISSE/ERKENNTNISSE:

- Die Wissenschaftler*innen prüften das Federated Learning - eine Technik des Machine Learning - und stellten fest, dass diese besonders für den effizienten und sicheren Datenaustausch geeignet ist. Beim Federated Learning die Daten nicht auf einem einzigen Server gespeichert, sondern dezentral auf Servern der einzelnen Akteure. Die Daten werden verschlüsselt und aggregiert als Parameter ausgetauscht. Die Akteure können auf die aggregierten Parameter zugreifen und zielgerichtet auswerten.
- Zudem identifizierten die Wissenschaftler*innen zwei Anwendungsfälle, die sich als Untersuchungsgegenstand besonders eigneten: die „Intelligente Kreuzung“ und das „Vernetzte Lernen im öffentlichen Verkehr“.
- „Intelligente Kreuzung“: Die meisten Verkehrsunfälle geschehen durch menschliches Fehlverhalten. Ortungsgeräte und Sensoren können die Positionen von Verkehrsteilnehmer*innen erfassen, maschinelles Lernen kann die Informationen analysieren und auswerten. Wenn mehrere Akteure Mobilitätsdaten beisteuern, wird die Wahrscheinlichkeit höher, menschliches Fehlverhalten zu prognostizieren. Die Wissenschaftler*innen werteten Daten einer Kreuzung aus und ermittelten unnormales Fahrverhalten, das Unfälle verursachen kann. Um eine gute Datenbasis zu haben, erhoben sie an einer viel befahrenen Kreuzung in Hannover umfangreiche Bewegungsdaten verschiedener Fahrzeuge, Fußgänger*innen und Fahrradfahrer*innen.
- „Vernetztes Lernen im öffentlichen Verkehr“: Hier bezieht sich die Datenerhebung und -auswertung auf den öffentlichen Linienbus. Busfahrer*innen haben neben der Tätigkeit des Fahrens noch weitere Aufgaben, wie z. B. pflegebedürftigen Personen beim Einsteigen zu helfen. Die Forschungsidee besteht darin, Daten aus dem Innenraum des Busses zu sammeln (z. B. durch videobasierte Bildanalyse), um daraus das Angebot der Busunternehmen zu verbessern (z. B. Einstiegsmöglichkeiten für die pflegebedürftigen Personen optimieren).
- Für beide Anwendungsfälle entwarfen die Wissenschaftler*innen eine Datenarchitektur, die durch den Einsatz von Federated Learning Datenallianzen ermöglicht. Die Daten werden zunächst lokal gesammelt (einmal beim Auto, einmal im Bus) und dann auf dem Partner Level (z. B. Automobilhersteller oder Busunternehmen) aggregiert. Im nächsten Schritt werden die aggregierten Modellparameter entweder über einen Cloudserver oder direkt zwischen den beteiligten Partnern ausgetauscht und mittels Federated Learning ausgewertet. Die Beteiligten der Datenallianz ergänzen dadurch Lücken im eigenen Datensatz - im Anwendungsfall „Intelligente Kreuzung“ erhalten Automobilhersteller so z. B. Daten aus Verkehrskameras und können somit die Sicherheitssysteme der Vehikel verbessern.

SHARED UND MICRO MOBILITY

NUTZUNG VON SHARED UND MICRO MOBILITY

FORSCHUNGSINTERESSE:

Aus welchen Gründen nutzen Personen Shared Mobility und Micro Mobility?

VORGEHEN:

- Bei der Shared Mobility bieten Dienstleister*innen Fahrzeuge an, die Nutzer*innen teilen können (z. B. Car Sharing). Die Micro Mobility ist für die individuelle Mobilität konzipiert und ermöglicht eine leichte und kompakte Fortbewegung mit Kleinstfahrzeugen (z. B. Fahrräder, E-Scooter und Segways).
- Die Wissenschaftler*innen führten ein Webscraping von Shared-Mobility- und Micro-Mobility-Anbietern durch, um Daten über die Nutzungsdauer, die Strecke oder den Wochentag zu erfassen. Beim Webscraping werden Daten und Inhalte von Websites mithilfe geeigneter Software ausgewertet.
- Die Daten reicherten sie mit weiteren Informationen an, die potenzielle Einflussgrößen für die Nutzung der Dienste sind: Umweltdaten (Regularien, Mobilitätskosten für alternative Verkehrsträger, Soziokultur einer Region), externe Faktoren (öffentliche Verkehrspläne, lokale Ereignisse, Wetterdaten) und temporale Faktoren (Wochentag, Wochenende, Hauptreisezeiten, Ferien-/Urlaubszeiten).

ERGEBNISSE/ERKENNTNISSE:

- Der Datensatz der Wissenschaftler*innen enthält umfangreiche Informationen zur Nutzung von Micro-Mobility-Services. Diese Informationen sind wertvoll für Anbieter und Kommunen, um Dienstleistungen zu optimieren und Bedarfe besser zu erfassen.

- Die Wissenschaftler*innen visualisierten die Daten in einem Online-Tool. Das Ergebnis zeigt, dass Menschen Micro Mobility vor allem im Sommer, an Wochenenden und in Verbindung mit Großveranstaltungen nutzen. Einigen Anbietern gelingt eine bessere Flottenauslastung als anderen - bei gleichen Bedingungen (Wetter, Ort etc.).

SHARED UND MICRO MOBILITY

MACHINE LEARNING ZUR PROGNOSE VON MICRO-MOBILITY-BEDARFEN

FORSCHUNGSINTERESSE:

Inwiefern kann Machine Learning (ML) zur Ermittlung der Micro-Mobility-Bedarfe eingesetzt werden?

VORGEHEN:

Die Wissenschaftler*innen führten eine Literaturrecherche durch, um die Anwendung von ML zu prüfen.

ERGEBNISSE/ERKENNTNISSE:

- Die Wissenschaftler*innen stellten fest, dass der Einsatz von ML für verschiedene Aufgaben erfolgversprechend ist. Insbesondere im operativen Geschäft zur Vorbereitung, Durchführung und Nachbereitung der Fahrten ist ML hilfreich: Vor den Fahrten kann ML das Angebot auf den aktuellen räumlichen und zeitlichen Bedarf (z. B. für das Pendeln zur Arbeit) zuschneiden und dafür sorgen, dass die entsprechenden Bedarfe abgedeckt sind, indem die Fahrzeuge wirklich dort zur Verfügung stehen, wo sie genutzt werden. Während der Fahrten, z. B. beim Ride Sharing, kann ML die Zeitplanung von Fahrzeugen optimieren. Das bedeutet, dass ein Fahrzeug, welches einen Kunden von A nach B fährt, in der Nähe vom Zielort einen neuen Fahrgast mitnimmt, sodass kein zweites Fahrzeug angefordert werden muss. Nach den Fahrten kann ML den Wartungsbedarf der genutzten Fahrzeuge analysieren.
- Die Ergebnisse zeigen, dass ML das Potenzial hat, bestimmte Schritte zu automatisieren und der lokalen Geschäftseinheit Detailentscheidungen abzunehmen. Darüber hinaus ist ML erfolgversprechend für bestimmte Bereiche der strategischen oder taktischen Planung, insbesondere um dem Management durch die Auswertung von großen Datensätzen eine solide Entscheidungsgrundlage zur Verfügung zu stellen.

SHARED UND MICRO MOBILITY

ENTWICKLUNG EINES MACHINE-LEARNING-ALGORITHMUS

FORSCHUNGSINTERESSE:

Wie kann der Bedarf an Micro-Mobility-Services (MMS) vorhergesagt werden?

VORGEHEN:

- Die Wissenschaftler*innen entwickelten und trainierten einen Machine-Learning-Algorithmus auf Basis der erhobenen Micro-Mobility-Nutzungsdaten.
- Mithilfe des Algorithmus werteten sie die MMS-Nutzung im Stadtgebiet Hannover aus.

ERGEBNISSE/ERKENNTNISSE:

- Die Ergebnisse der Auswertung veranschaulichten die Wissenschaftler*innen in einem Gitternetz, das die räumliche Umgebung der Stadt Hannover abbildet.
- Zudem erstellten sie aus den Start- und Enddaten der MMS-Nutzung eine Auslastungs-Heat-Map für das Stadtgebiet. Die Heat-Map ist für die Entwicklung von Handlungsempfehlungen hilfreich. Auch für Entscheider*innen im öffentlichen Nahverkehr ist die Heat-Map nützlich, weil sie Informationen zum Einsatz der Flotte bietet: Wenn auf einer bestimmten Strecke besonders viele Micro Mobility Services genutzt werden, scheint es einen großen Bedarf an Transportmitteln zu geben, sodass hier z. B. (weitere) Busse eingesetzt werden könnten.