



KI4Safety

Eingehende Darstellung

KI4Safety: Einsatz von Methoden der Künstlichen Intelligenz für die Verkehrssicherheitsarbeit

Projektpartner: SSP Consult Beratende Ingenieure GmbH und Deutsches Zentrum für Luft- und Raumfahrt e.V. Förderkennzeichen: 19F2082A

Autoren: O. Böttcher, J. Fuchs, R. Hoffmann, R. Katzler, N. Kornfeld A. Leich, J. Meuter, J. Niemeijer, G. Srinivas, M. Tepper, S. Trupat, P. Wagner

Inhaltsverzeichnis

Management Summary	5
1. Einleitung	6
2. Untersuchungsansatz.....	7
2.1. Unfallprognosemodell mittels VAE	7
2.2. Maßnahmenkatalog MaKaU und evidenzbasierte Verkehrssicherheitsarbeit	9
2.3. MaKaU aus Sicht von KI4Safety	11
2.4. Auswahl der Maßnahmen	17
2.5. Studiendesign	18
2.6. Methodische Überlegungen zur statistischen Auswertung: Regression zur Mitte.....	22
2.7. Bedeutung von Sichtbehinderungen	27
2.8. Messung von Sichtbehinderungen	31
2.8.1. Sichtbehinderungen aus Sichtdreieck	32
2.8.2. Verfügbarkeit von Trainingsdaten	35
2.8.3. Fazit	35
2.9. Zusammenfassung	35
3. Implementierung	37
3.1. Erkennung von Verkehrszeichen	37
3.1.1. Trainingsdatensätze	38
3.1.2. Netzarchitektur	39
3.1.3. Ergebnisse	40
3.1.4. Fazit und Ausblick	43
3.2. Erkennung von Mittelinseln	43
3.2.1. Erstellung der initialen Datenbasis	44
3.2.2. Entwicklung und Training der Architektur	46
3.2.3. Strategien um die limitierte Datenbasis zu kompensieren	46
3.3. Aufbau der Datenbank	49
3.4. Datenextraktion mittels OpenStreetMap und Google Street View	52
4. Evaluierung.....	53
4.1. Durchführung einer Studie: Workflow	53
4.2. Erfahrungen bei der Zusammenstellung von Stichproben.....	55
4.3. Fallstudie Kreisverkehre	61
4.3.1. Stichprobe	61
4.3.1. Modellauswahl.....	64
4.3.2. Eingehende Betrachtung der Stichprobe.....	72
4.3.1. Änderungen an Verkehrsführungen (Vorher/Nachher Vergleich)	77

4.3.1. Analyse der Stichprobe	79
4.3.1. Nicht signifikante Einflussparameter	85
5. Projektdurchführung.....	87
5.1. Aktivitäten der Projektpartner	87
5.2. Aktivitäten zur Datenbeschaffung.....	88
5.3. Verbreitung und Bekanntmachung des Projektes.....	90
6. Zusammenfassung und Ausblick	92
6.1. Zusammenfassung	92
6.2. Reflexion der Ergebnisse	92
6.3. Ausblick.....	95
6.4. Fazit	96
7. Anhang	98
Anlage 1: MaKaU-Auswertung	98
Anlage 2: Auszug aus MaKaU-Auswertungstabelle.....	99
Anlage 3: Auszug aus Luftbild-Auswertung in Baden-Württemberg	100
Anlage 4: Beispiel für die Nutzung von bereits in QGIS vorhandenen Funktionen um Stichprobenparameter zu extrahieren	101
8. Literaturverzeichnis.....	108

Abkürzungsverzeichnis

ADAC	Allgemeiner Deutscher Automobil-Club
AO	Außerorts
BAST	Bundesanstalt für Straßenwesen
BAYSIS	Bayerisches Straßeninformationssystem
BMVI	Bundesministerium für Verkehr und digitale Infrastruktur
DLR	Deutsches Zentrum für Luft- und Raumfahrt
DTV	Durchschnittliche Tägliche Verkehrsstärke
DVR	Deutscher Verkehrssicherheitsrat
FCD	Floating Car Data
FDZ	Forschungsdatenzentrum
FGSV	Forschungsgesellschaft für Straßen und Verkehrswesen
IO	Innerorts
km/h	Kilometer in der Stunde
KI	Künstliche Intelligenz
LSA	Lichtsignalanlage
m	Meter
MaKaU	Maßnahmenkatalog gegen Unfallhäufungen
OSM	OpenStreetMap
QGIS	Freie Geo-Informations-Software
StVO	Straßenverkehrsordnung
StVU	Straßenverkehrsunfälle
UDV	Unfallforschung der Versicherer
UTM	Universal Transverse Mercator
VAE	Variational Autoencoder

Management Summary

Häufungsstellen für Verkehrsunfälle haben unterschiedlichste Ursachen. Im Rahmen des Projektes KI4Safety wird ein System entwickelt, welches mit Hilfe statistischer Methoden und neuartiger Verfahren aus dem Bereich der Künstlichen Intelligenz und des Deep Learnings Daten auswertet um Einflussfaktoren auf Unfallhäufungsstellen zu identifizieren.

Als Daten werden Datenbanken mit Bildern der Unfallorte und deren Umgebung, frei verfügbares Kartenmaterial und verkehrstechnische Kenngrößen wie DTV und Geschwindigkeitsbegrenzungen herangezogen.

Basierend auf dieser Auswertung bietet das System Unterstützungsleistungen für Praktiker in der Verkehrssicherheitsarbeit an, so z.B. Verkehrssicherheitsforschern und letztlich Mitgliedern der Unfallkommission. Es ermöglicht vergleichende Untersuchungen zum Effekt von Maßnahmen zur Gestaltung von Verkehrsführungen mit größeren Stichproben als bisher. Die Vergrößerung der Stichproben erlaubt eine differenziertere Stichprobenauswertung, höhere statistische Signifikanzniveaus hinsichtlich der getroffenen Aussagen und eine genauere Bestimmung der Effektgrößen, d.h. der zu erwartenden Verringerung der Anzahl von Unfällen.

Gegenstand des vorliegenden Berichts ist die Darstellung der Anwendungsszenarien, der damit verbundenen konzeptionellen Arbeiten im Rahmen des Projektes KI4Safety, der entwickelten Lösung sowie der durchgeführten Validierungsprozesse und der gewonnenen Erkenntnisse. Die entwickelte Lösung umfasst

- eine Datenbank,
- Python-Scripte zur Befüllung der Datenbank,
- KI-Module zur Befüllung der Datenbank,
- ein QGIS-Plugin zur Filterung, welches bei der Zusammenstellung von Stichproben zum Einsatz kommt, sowie
- statistischen Methoden für die Auswertung und den Stichprobenvergleich.

1. Einleitung

Das Verkehrssicherheitsprogramm des BMVI aus dem Jahr 2011 hat eine Verringerung der Zahl von getöteten Verkehrsteilnehmern um 40% bis 2020 als Zielperspektive genannt. Es wird jedoch trotz entsprechender Erfolge in der jüngeren Vergangenheit in der Praxis immer schwieriger, die Zahl der Verkehrstoten weiter zu senken. Innovative Ansätze zur Ableitung effektiver und kostengünstiger Maßnahmen sind daher notwendig.

Im Projekt KI4Safety wird in diesem Kontext ein System entwickelt, welches mit Hilfe statistischer Methoden und neuartiger Verfahren aus dem Bereich der Künstlichen Intelligenz (KI) mittels Deep Learning Daten auswertet, um darauf basierend Einflussfaktoren auf Verkehrsunfälle an Knotenpunkten mit unterschiedlichen Geometrien und Ausstattungsmerkmalen quantitativ bewerten zu können. Auf Basis der Rückmeldungen von den Zuständigen von Polizeibehörden, Unfallkommissionen und Planungsabteilungen sowie nach Abstimmung mit den Experten der assoziierten Partner wurden folgende Einsatzszenarien für den Einsatz von KI-Methoden in der Verkehrssicherheitsarbeit definiert:

- Szenario 1: Mitglieder der Unfallkommission sind sich nach Abwägung der Kosten und der sonstigen Randbedingungen uneins darüber, ob die Umsetzung einer bestimmten Maßnahme zur Erhöhung der Verkehrssicherheit zumutbar ist. Sie möchten ihren Disput auflösen, indem sie eine verlässliche Aussage zur Wirksamkeit der Maßnahme erhalten. Diese Aussage kann aus Sicht der mathematischen Statistik dadurch getroffen werden, dass eine Effektgröße und eine Irrtumswahrscheinlichkeit angegeben werden. Diese beiden Zahlen liefert ihnen eine Studie, welche mit dem Instrumentarium von KI4Safety durchgeführt wurde. Nachdem sie z.B. erfahren, dass durch Umsetzung der Maßnahme zwar mit einer Verringerung der Unfallzahlen um einen zweistelligen Prozentbetrag zu rechnen ist, aufgrund der dünnen Datenbasis die Irrtumswahrscheinlichkeit aber vergleichsweise hoch ist, kommen sie zu einer Entscheidung.
- Szenario 2: Mitarbeiter derjenigen Institution, welche den Maßnahmenkatalog veröffentlicht, erhalten die entsprechende Anfrage von den Mitgliedern der Unfallkommission. Sie nutzen die im Rahmen von KI4Safety entwickelten Werkzeuge und die Datenbasis, welche durch KI4Safety über die m-Cloud zur Verfügung gestellt wurde, um eine Big-Data Studie durchzuführen. Im Ergebnis kann die Irrtumswahrscheinlichkeit verringert werden.

Im vorliegenden Bericht wird in Abschnitt 2 detailliert auf den methodischen Ansatz (Untersuchungsansatz) von KI4Safety eingegangen. In Abschnitt 3 finden sich alle Details zur Implementierung. Die durchgeführten Evaluierungsprozesse sind dem Abschnitt 4, die Details zu den Aktivitäten im Rahmen der Projektdurchführung dem Abschnitt 5 zu entnehmen.

Abschnitt 6 umfasst eine Zusammenfassung und einen Ausblick zum Projekt.

2. Untersuchungsansatz

2.1. Unfallprognosemodell mittels VAE

Die Entstehung von Verkehrsunfällen wird von vielen Umfeldfaktoren und deren Kombinationen maßgeblich beeinflusst. Ziel von KI4Safety ist es, Methoden der künstlichen Intelligenz einzusetzen um die Verkehrssicherheitsarbeit zu unterstützen.

In den Voruntersuchungen von KI4Safety wurde gezeigt, dass es möglich ist ein Unfallprognosemodell zu realisieren, welches allein basierend auf Luftbildern Unfallzahlen schätzt. Dabei wurde das Konzept des Variational Autoencoder (VAE) verwendet. Ein Autoencoder kann genutzt werden, um Bildinhalte von Trainingsbildern in einen Merkmalsraum zu transformieren, der eine viel geringere Dimension hat, als die Bilder selbst (Bildkompression).

Dabei soll es möglich sein, das ursprüngliche Bild aus dem komprimierten Merkmalsraum wiederherzustellen. Autoencoder werden darauf trainiert, Bilder möglichst gut komprimieren und entpacken zu können, vergleichbar mit gängigen Bildkompressionsalgorithmen wie gif, jpg usw.




Abbildung 1: Variational Autoencoder zur Kompression und Dekompression von Luftbildern

Im Merkmalsraum kann jedes Eingangsbild als Vektor repräsentiert werden. Diese Darstellungsform wird als latentes Variablenmodell bezeichnet. Das Konzept des Variational Autoencoder sieht zusätzlich vor, dass die entsprechenden Vektoren des Trainingsdatensatzes im Merkmalsraum gaußverteilt sind und dass die Abstände zwischen benachbarten Bildern und benachbarten Vektoren ähnlich sind. Daher ist die latente Variable eines VAE eine vergleichsweise gut generalisierende Darstellungsform und es ergeben sich folgende Eigenschaften:

- Man kann die Eingangsbilder des Trainingsdatensatzes vergleichsweise gut aus dem entsprechenden Vektor rekonstruieren.
- Man kann Bilder, die im Trainingsdatensatz gar nicht enthalten waren gut rekonstruieren, solange sie nicht ganz aus dem Rahmen des Trainingsdatensatzes fallen. Enthält der Trainingsdatensatz Luftbilder von Kreuzungen und Straßen, so können Kreuzungen und Straßen gut rekonstruiert werden, Schmetterlinge aber z.B. nicht.
- Man kann synthetische Bilder erzeugen, indem man der latenten Variablen Werte zuweist, welche z.B. Zwischenwerte zwischen Trainingsbildern sind.

Folglich ist es aussichtsreich, Unfallzahlen basierend auf der latenten Variablendarstellung zu schätzen (vgl. Abbildung 2). Dadurch sind gute Schätzergebnisse für Luftbilder zu erwarten, die das neuronale Netz vorher noch nie „gesehen“ hat. Entsprechend gut sind die experimentellen Ergebnisse. Das Netz errät in fast 75% der Testfälle richtig, ob eine Kreuzung gefährlich ist oder nicht und es kann auch die Zahl der Unfälle/Jahr schätzen, wobei der mittlere Fehler 1,9 Unfälle/Jahr beträgt.




Abbildung 2: Prognose von Unfallzahlen mittels VAE

Wenn das neuronale Netz also gewisse Hinweise auf eine erhöhte Unfallzahl erkennen kann, so ist es naheliegend Methoden einzusetzen um in das Netz „hineinzusehen“. Dies ist im Rahmen der Vorarbeiten zu KI4Safety geschehen. Das Ziel dabei war festzustellen, inwiefern solche Einblicke die Arbeit von Unfallkommissionen unterstützen können.

Zur Unterstützung bei der Identifikation infrastruktureller Defizite können Heatmaps generiert werden. Class Activation Maps, beschrieben in (Zhou et al., 2016), stellen eine Möglichkeit dar, um Bereiche in Eingabebildern so zu markieren, dass deutlich wird, welche Bereiche für den Klassifikator einen hohen Einfluss auf die Klassifikation haben. Zur Erstellung der Heatmaps musste die Struktur der Neuronalen Netze angepasst werden (vgl. Abbildung 3). Im Ergebnis konnten Bilder erzeugt werden, welche zu einem analysierten Bild hell markieren, welche Bildteile die Entscheidung des neuronalen Netzes besonders beeinflussen.

Dabei stellte sich heraus, dass insbesondere Fahrzeuge, die sich zufällig im Bild aufhielten, eine starke Aktivierung hervorriefen. Da die Zahl der Fahrzeuge, die sich zufällig im Bild befinden einen Hinweis auf die Verkehrsstärke liefert, ist es möglich, dass das Unfallprognosemodell die Unfallprognose im Wesentlichen auf die Verkehrsstärke stützt. Da dies für die Verkehrssicherheitsarbeit nicht hilfreich wäre und andere Visualisierungsmethoden nach aktuellem Stand der Technik nicht greifbar erscheinen, wurde in KI4Safety ein neuer Ansatz gewählt.




Abbildung 3: Angepasste Struktur des Variational Regression Model, um die Erzeugung von Class Activation Maps zu unterstützen



Abbildung 4: Ausgabe der Class Activation Map für die Kreuzung mit der höchsten Unfallhäufigkeit

2.2. Maßnahmenkatalog MaKaU und evidenzbasierte Verkehrssicherheitsarbeit

Ein latentes Variablenmodell ist die Repräsentation eines Eingangsbildes, welche gewissermaßen auf dem Erfahrungswissen basiert, welches das neuronale Netz dadurch gesammelt hat, dass es Bilder eines Trainingsdatensatzes verarbeitet hat. Dabei lernt das neuronale Netz, ein Eingangsbild möglichst fehlerfrei zu reproduzieren.

Das Pendant zum latenten Variablenmodell ist in der Verkehrssicherheitsarbeit der Maßnahmenkatalog gegen Unfallhäufungen (MaKaU). Dieser enthält das gesammelte praktische Wissen um relevante Merkmale in der Beschilderung und in der Verkehrsführung, welche nach der Erfahrung der Arbeit in den Unfallkommissionen einen Einfluss auf das Unfallgeschehen haben. Es ist anzunehmen, dass ein neuronales Netz lernen kann, aus dem Vorhandensein der Merkmale nach MaKaU das Unfallgeschehen besser zu reproduzieren, als dies allein basierend auf Luftbildern möglich ist. In KI4Safety wurde daher entschieden, statt eines abstrakten latenten Variablenmodells die Merkmale nach MaKaU näher zu betrachten. Es hat sich herausgestellt, dass die Quantifizierung des Einflusses von Merkmalen nach MaKaU auf das Unfallgeschehen ein aussichtsreicher Ansatz ist, um mittels Auswertung von großen Datenmengen (Big Data) mittels künstlicher Intelligenz einen Mehrwert für die Arbeit der Unfallkommissionen zu erbringen. Nach aktuellem Stand von Wissenschaft und Technik ist bisher nicht ausreichend untersucht, wie

- effektiv eine bestimmte Maßnahme nach MaKaU ist, d.h. welche Reduktion der Unfallzahl zu erwarten ist (Effektgröße) und
- wie sicher es ist, dass diese Maßnahme überhaupt wirkt (Irrtumswahrscheinlichkeit bzw. fehlende empirische Absicherung der Aussagen).

Beides – Effektgröße und Irrtumswahrscheinlichkeit bzw. empirische Relevanz – werden in naturwissenschaftlichen Studien üblicherweise durch die statistische Auswertung größerer Stichproben bestimmt.

In Studien zur Wirksamkeit der Maßnahmen wurden bisher sehr kleine Stichproben, wie z.B. mit einem Umfang von sechs oder weniger Fällen [Maier2016], herangezogen. Es besteht Bedarf, das Wissen über die Wirksamkeit der Maßnahmen nach MaKaU durch Auswertung großer Stichproben abzusichern. Die Nutzung moderner Methoden der künstlichen Intelligenz auf großen Datenmengen ist in diesem Zusammenhang sinnvoll, weil in der Regel effektiver einsetzbar.

Es wurde wie folgt vorgegangen:

1. Es wurde eruiert, welche Datenquellen zur Verfügung stehen, um das Auftreten von Merkmalen nach MaKaU zu registrieren. Folgende Datenquellen wurden identifiziert:
 - a. Unfalldatenbanken der einzelnen Bundesländer
 - b. Luftbilder unterschiedlicher Jahre, einsehbar beispielsweise über Google Earth
 - c. Befahrungsbilder von Google Street View
 - d. Befahrungsbilder von Streckenbefahrungen, welche die Verkehrsministerien der Länder in Auftrag geben (Beispiele: <https://www.nwsib-online.nrw.de/>, www.bay-sis.bayern.de)
 - e. Der Datenpool von HERE Deutschland (www.here.com), welcher die Positionen von Verkehrszeichen samt Historie beinhaltet

2. Alle Maßnahmen von MaKaU wurden gesichtet um zu ermitteln, wie viele davon sich für eine Big-Data Analyse eignen. Dabei hat sich herausgestellt, dass 118 von den 272 Maßnahmen gut geeignet sind um mit den gängigen Datenquellen große Stichproben zu generieren (siehe auch weitergehende Erläuterungen im Kapitel 3.1).
3. Es wurden Voruntersuchungen durchgeführt um festzustellen wie gut die Detektion von Merkmalen nach MaKaU tatsächlich funktioniert.
4. Es wurden Betrachtungen zur statistischen Untersuchungsmethodik durchgeführt.
5. Es wurden Maßnahmen ausgewählt, anhand derer die Wirksamkeit der Vorgehensweise demonstriert werden kann.

In den folgenden Abschnitten wird detailliert auf die genannten Punkte eingegangen.

2.3. MaKaU aus Sicht von KI4Safety

Alle MaKaU-Maßnahmen wurden von den Projektpartnern SSP und DLR auf ihre Möglichkeit zur evidenzbasierten Bewertung mittels künstlicher Intelligenz auf das Vorhandensein relevanter Big Data Datenquellen hin untersucht. Dabei wurde jede Maßnahme in eine von folgenden drei Kategorien eingeordnet:

- Gute Aussichten, die relevanten Merkmale zu detektieren (+)
- Die relevanten Merkmale sind zu detektieren aber es sind noch technische Fragen zu klären (0)
- Detektion der relevanten Merkmale mittels künstlicher Intelligenz nicht möglich (-)

Bei der initialen Bewertung sind beide Projektpartner zu teils deutlich unterschiedlichen Einschätzungen gekommen. Einer der wesentlichen Gründe war die unterschiedliche Interpretation der Defizitbeschreibung der MaKaU-Maßnahmen.

Daher wurden die Defizitbeschreibungen der MaKaU-Maßnahmen genauer betrachtet. Hier konnten anhand einiger Maßnahmen aus Projektsicht nicht eindeutige Beschreibungen identifiziert werden. Als Beispiel ist hier die MaKaU-Maßnahme 225 dargestellt:

Sichtbeziehung durch Wegnahme des Rechtsabbiegestreifens verbessern

Defizit(e)

Sichtbehinderung durch
Fahrzeuge auf dem
Rechtsabbiegestreifen



Abbildung 5: MaKaU-Maßnahme 225

Diese Maßnahme suggeriert, dass durch die Wegnahme des Rechtsabbiegestreifens die Sichtbeziehung vom Wartepflichtigen auf den bevorrechtigten Verkehr verbessert wird. Betrachtet man die Bilder, ist eine Verbesserung der Sichtbeziehung nicht offensichtlich. Vielmehr scheint der Lkw im Bild nach Einführung der Maßnahme die Sicht auf den bevorrechtigten Verkehr noch stärker einzuschränken als vorher.

Trotzdem ist die Maßnahme sicherlich wirksam, wobei gemutmaßt werden kann, dass weitere Effekte eine Rolle spielen: So verringert sich die gefahrene Geschwindigkeit der bevorrechtigten Geradeausfahrer durch den abbremsenden Rechtsabbieger auf dem Fahrstreifen. Dadurch fahren die folgenden Fahrzeuge mit einer geringeren Geschwindigkeit in den Knotenpunktbereich ein, woraus sich ein Sicherheitsvorteil ergibt. Andererseits kann es aber auch z.B. durch Fehleinschätzungen des nachfolgenden Verkehrs vermehrt zu Abbiegeunfällen durch Auffahren auf den Abbiegenden kommen.

Damit ist klar, dass das Verständnis der Wirkung der verschiedenen Maßnahmen sich nicht immer auf den ersten Blick erschließt. Daher wurden bei allen 273 MaKaU-Maßnahmen die Defizitbeschreibungen detailliert geprüft und neue projektspezifische Beschreibungen der Maßnahme hinzugefügt. Ziel war es, die Defizite exakter zu beschreiben, um ein genaueres Verständnis der Wirkungsweise zu bekommen und eine einheitliche Bewertung möglich zu machen.

Beispielhaft ist hier die Maßnahme 114 dargestellt:

Linksabbiegen durch Beschilderung und Markierung unterbinden (ggf. Blockumfahrung anbieten)

Defizit(e)

hohe Verkehrsstärke (geringe Zeitlücken) und schwere Unfälle



Abbildung 6: MaKaU-Maßnahme 114

Defizit der Verkehrssituation ist nach MaKaU, dass an dieser Stelle eine hohe Verkehrsstärke zu Grunde liegt und es zu schweren Unfällen kommt. Was jedoch anhand der Defizitbeschreibung und auf den Bildern (vgl. Abbildung 6) nicht auf den ersten Blick erkennbar ist, sind die Konflikttypen. Hier ist zu erkennen, dass es sich bei der Maßnahme um Unfälle mit Radfahrern und Fußgängern im Abbiegebereich handelt (vgl. Abbildung 7). Dies war im ersten Bewertungslauf teilweise übersehen worden.

Im Rahmen von KI4Safety wurde eine projektbezogene spezifische Defizitbeschreibung erstellt (vgl. Tabelle 1).

Tabelle 1: Spezifische Defizitbeschreibung der MaKaU-Maßnahme 114

Defizitbeschreibung MaKaU	Defizitbeschreibung KI4Safety
Hohe Verkehrsstärke (geringe Zeitlücken) und schwere Unfälle	Bei hohen Verkehrsstärken (geringen Zeitlücken) kommt es aufgrund von Einschränkungen in Sicht und Erkennbarkeit vermehrt zu schweren Abbiegeunfällen von linksabbiegenden Kfz mit Fußgängern oder Radfahrern, da immer wieder Radfahrer und Fußgänger in Unfälle verwickelt wurden. Fußgänger und Radfahrer werden vom links Abbiegenden übersehen.

Innerorts · Knotenpunkt ohne LSA · ● Abbiege-Unfall (AB)

Linksabbiegender mit Fußgänger oder Radfahrer (beide Richtungen)



Überprüfung:

- Sicht auf annähernde Radfahrer bzw. Radverkehrsanlage
- Erkennbarkeit der Radverkehrsanlage
- Erkennbarkeit des Fußwegs
- Verkehrsstärke des bevorrechtigten Verkehrs

[→ Details](#)

Innerorts · Knotenpunkt ohne LSA · ● Abbiege-Unfall (AB)

Linksabbiegender mit Radfahrer (in entgegengesetzter Richtung)



Überprüfung:

- Sicht auf annähernde Radfahrer bzw. Radverkehrsanlage
- Erkennbarkeit der Radverkehrsanlage
- Verkehrsstärke des bevorrechtigten Verkehrs

[→ Details](#)

Innerorts · Knotenpunkt ohne LSA · ● Abbiege-Unfall (AB)

Linksabbiegender mit Radfahrer (in gleicher Richtung)



Überprüfung:

- Sicht auf annähernde Radfahrer bzw. Radverkehrsanlage
- Erkennbarkeit der Radverkehrsanlage
- Verkehrsstärke des bevorrechtigten Verkehrs

[→ Details](#)

Abbildung 7: Konflikttypen der MaKaU-Maßnahme 114

Zusätzlich wurden jeder Maßnahme identifizierungsrelevante Merkmale zugeordnet. In diesem Zusammenhang wurden zu allen Merkmalen auch mögliche Datenquellen definiert, aus denen die

Informationen über das Vorhandensein des Merkmals gewonnen werden können. Dabei wurde auch die Verfügbarkeit der Daten beurteilt.

Auf Grundlage der modifizierten MaKaU-Defizit-Beschreibungen sowie den identifizierten Merkmalen und Datenquellen wurde eine erneute Bewertung aller Maßnahmen durchgeführt. Das Ergebnis dieser zweiten Bewertung ist im Vergleich zur ersten Bewertung deutlich verändert. Mit konsequenter Anwendung dieses Vorgehens sind potentiell mehr Maßnahmen dafür geeignet, mit entsprechenden Daten mittels KI verifiziert zu werden (vgl. Abbildung 8 und Abbildung 9)




Abbildung 8: Ergebnis der ersten Bewertung




Abbildung 9: Ergebnis der zweiten Bewertung

In einer dritten Bewertung wurden ausgewählte, positiv eingestufte Maßnahmen detaillierter geprüft. Dabei wurde nach den folgenden Kategorien unterschieden:

Tabelle 2: Kategorien und Ausprägungen für die Merkmalsbewertung

Kategorie	Ausprägung
<u>Situation vorher</u>	bauliche und verkehrsregelnde Informationen zu Verkehrszeichen, LSA etc.
<u>Situation nachher</u>	bauliche und verkehrsregelnde Informationen zu Verkehrszeichen, LSA etc.
<u>Unfalltyp</u>	1 - Fahr Unfall, 2 - Abbiegeunfall, etc.
<u>Unfallkategorie</u>	1 – Unfall mit Getöteten, 2 – Unfall mit Schwerverletzten etc.
<u>Charakteristik der Unfallstelle</u>	1 – Kreuzung, 2 – Einmündung
<u>Art der Verkehrsteilnehmer</u>	21 – Pkw, 33 – Linienbus, etc.
<u>Verkehrsstärke zum Unfallzeitpunkt</u>	Hoch/Mittel/Niedrig (Geeignete Schwellwerte müssen gefunden werden und sollten später direkt in MaKaU dokumentiert werden)
<u>Uhrzeit</u>	
<u>Wochentag</u>	

Für den Fall der MaKaU-Maßnahme 114 ist im Anhang als Anlage 2 eine solche Bewertung angegeben. Der wesentliche Unterschied der Vorher-Nachher-Situation ist durch das Vorhandensein des Verkehrszeichens Z214-20 StVO gekennzeichnet (vgl. Abbildung 10).



Abbildung 10: Verkehrszeichen Z214-20 StVO

Der in diesem Fall zuzuordnende Unfalltyp ist 2 (Abbiegeunfall). Es werden alle Unfallkategorien betrachtet (1-6); die Charakteristik der Unfallstelle wird mit 1 oder 2 angegeben (Kreuzung oder Einmündung). Für die MaKaU-Maßnahme 114 ist vor allem die Art der Verkehrsteilnehmer relevant, die mit 71 oder 81 angegeben wird (71 – Radfahrer, 72 - Pedelec oder 81 - Fußgänger). Darüber hinaus ist die Verkehrsstärke zum Unfallzeitpunkt mit hoch zu bewerten. In diesem Beispiel nicht relevant sind die Uhrzeit und der Wochentag der Unfälle.

Problematisch ist die Abhängigkeit der Auswertung von mehreren Faktoren hinsichtlich der Datenqualität und -quantität. Bei Satellitenaufnahmen bzw. Befahrungsbildern ist die Bewertung abhängig von der Aktualität und der Qualität der Fotos. Betrachtet man die Unfalldaten sind diese abhängig von der Sorgfalt und Genauigkeit der Unfallberichte. Darüber hinaus ist es wichtig, dass alle vorhandenen Daten vollständig und digitalisiert verfügbar sind. Ist die Datenqualität nicht ausreichend und/oder liegen nicht ausreichend Daten vor, kann keine korrekte Auswertung stattfinden.

2.4. Auswahl der Maßnahmen

Bei den Untersuchungen im Rahmen von KI4Safety sollen zuerst folgende Maßnahmen im Fokus stehen, da deren Merkmale am einfachsten aus Luft- und Befahrungsbildern extrahiert werden können:

Maßnahmen, bei denen Sichtbeziehungen eine Rolle spielen:

- <https://makau.bast.de/massnahmen/159>
- <https://makau.bast.de/massnahmen/338>
- <https://makau.bast.de/massnahmen/377>
- <https://makau.bast.de/massnahmen/379>
- <https://makau.bast.de/massnahmen/400>
- <https://makau.bast.de/massnahmen/405>
- <https://makau.bast.de/massnahmen/474>

Abknickende Vorfahrt aufheben:

- <http://makau.bast.de/massnahmen/123>

Maßnahmen bei denen Fahrbahnteiler eine Rolle spielen:

- <https://makau.bast.de/massnahmen/649>
- <https://makau.bast.de/massnahmen/126>
- <https://makau.bast.de/massnahmen/238>
- <https://makau.bast.de/massnahmen/708>
- <https://makau.bast.de/massnahmen/246>
- <https://makau.bast.de/massnahmen/223>

Um die Wirksamkeit dieser Maßnahmen bewerten zu können, müssen folgende Merkmale erkannt werden:

- Fahrbahnteiler in Luftbildern
- Beschilderungen in Befahrungsbildern
- Sichtbehinderungen in Befahrungsbildern

2.5. Studiendesign

Um Verkehrssicherheit zu bewerten sind über die Jahre viele Verfahren vorgeschlagen worden. In diesem Projekt liegen zwei davon im Fokus: der Vorher-Nachher Vergleich und der Vergleich auf der Basis von Ensembles.

Der Vorher-Nachher-Vergleich ist konzeptionell das einfachere Vorgehen und wird von den Unfallkommissionen bei der Wirkungsanalyse einer Maßnahme im Rahmen der örtlichen Unfalluntersuchung angewendet. Für eine Unfallhäufungsstelle wird anhand diverser Auswertungen eine Maßnahme beschlossen und nach bestimmten Zeiträumen ermittelt, ob sie gewirkt hat, d.h. ob die Anzahl der Unfälle an diesem Ort gesunken ist.

Der Vergleich von Ensembles schaut auf viele Orte an denen Unfälle passieren und versucht zum Beispiel modellgestützt herauszufinden, welche Charakteristika der verschiedenen Orte besonders großen Einfluss auf die Entstehung von Unfällen haben.

Beide Methoden haben Nachteile: bei der Vorher-Nachher-Analyse ist das größte Problem die Vorauswahl: es gibt zwar Kriterien wie Unfallhäufungen zu identifizieren und zu definieren sind, aber dennoch steckt eine gewisse Willkürlichkeit in dieser Definition. Gerade die Vorauswahl ist im statistischen Sinn eine sogenannte Voreingenommenheit (Bias), im Fall von Unfällen macht die Vorauswahl diese Methode anfällig gegen den Regression-zur-Mitte Effekt (R2M). Die R2M besagt, dass die zufällige Komponente von Unfällen sehr oft dazu führt, dass nach einer Serie von schlechten Jahren mit besonders vielen Unfallereignissen von ganz alleine wieder ein oder mehrere gute Jahre mit weniger Unfällen folgen können. Somit ist oft nicht auseinander zu halten ob der beobachtete Rückgang auf die Maßnahme zurück zu führen ist, oder ob sich die Unfallzahlen auch ohne Implementierung der Maßnahme verringert haben.

Für beide Ansätze problematisch ist die Wirkungsanalyse bei Maßnahmenkombinationen, da die Wirkung der einzelnen Maßnahmen dann nur schwer zu ermitteln ist.

Der Ensembleansatz sagt, dass man zu den Unfallzahlen noch weitere Variablen verwendet, von denen man annimmt, dass sie Einfluss auf das Unfallgeschehen haben. Das sind im Einzelfall sehr viele mögliche Variablen (Kreuzung / Straßenabschnitt, Kurvigkeit, Geschwindigkeitsbegrenzungen, Überholverbote, Umgebung, aber auch welche Fahrzeuge waren beteiligt, usw.). Ein einfaches Beispiel, das häufig herangezogen wird, ist eine mögliche Begrenzung der zulässigen Höchstgeschwindigkeit. Zwar müsste man noch zwischen der Begrenzung selbst und den tatsächlich gefahrenen Geschwindigkeiten trennen, dies ist aber oft mangels Daten gar nicht möglich. Deshalb werden die beiden hier gleichgesetzt.

Während die meisten Menschen, im Einklang mit der Physik, zustimmen würden, dass die Unfallschwere mit höheren Geschwindigkeiten zunimmt, ist es sehr viel schwieriger zu sagen, ob auch

das Unfallrisiko (also die Anzahl Unfälle pro gefahrenem km) mit höheren Geschwindigkeiten zunimmt. In einigen wissenschaftlichen Arbeiten wurden solche negativen Zusammenhänge beschrieben: je höher die erlaubte Geschwindigkeit, desto kleiner wird die Unfallrate¹ (vgl. Abbildung 11).

Das Problem dabei ist, dass die Geschwindigkeit eng an den Straßentyp gekoppelt ist. Hohe Geschwindigkeiten findet man typischerweise bei besonders sicheren Straßentypen, z.B. Autobahnen, die aufgrund ihrer Konstruktion und Organisation sicherer sind als andere Straßen. Wenn das Modell dies nicht berücksichtigt, dann kommt es zu einem falschen Ergebnis. Das ist eine große Schwäche des Ensembleansatzes: das Modell muss korrekt spezifiziert sein. Diese korrekte Spezifikation aber ist nicht immer so offensichtlich wie im Beispiel mit den Geschwindigkeiten.

Was wäre optimal? In der Medizin werden Medikamente bzw. Behandlungen mit Placebos verglichen, d.h. man vergleicht im Idealfall nur **eine** Änderung (Behandlung ja/nein), und versucht alles andere gleich zu lassen. Auf ein Beispiel im Verkehr übertragen hieße das: eine bestimmte Lichtsignalanlagenschaltung (z.B. das bedingt verträgliche Abbiegen verbieten) könnte die Anzahl Unfälle reduzieren. Um das zu testen müsste man eine vorab festgelegte, zufällig ausgewählte Anzahl von Kreuzungen damit ausstatten und mit einer ähnlichen Auswahl von Kreuzungen vergleichen, bei denen man nichts macht. Verkehrssicherheitsarbeit funktioniert im Allgemeinen nicht auf diese Weise. Vielmehr ist die Vorgehensweise der Unfallkommissionen, auf Unfallschwerpunkte zu schauen, Maßnahmen zu finden, umzusetzen und später, anhand der Unfallzahlen die Wirksamkeit zu bewerten.

Zu erwähnen wäre noch, dass man auch im Fall des Vorher-Nachher-Vergleichs mögliche Variablen kontrollieren muss: so könnte es sein, dass eine Kreuzung durch eine Maßnahme für Radfahrende attraktiver, für den motorisierten Individualverkehr aber unattraktiver wird. Dann würde sich die Nachfrage ändern, und die Anzahl Unfälle würde einfach deshalb kleiner, weil an den ausgestatteten Kreuzungen weniger Autos fahren.

¹ Hauer, Ezra. "When Correctly Specified and Well Estimated Models Mislead.", 2019




Figure 1. How the accident rate declines with average speed. (Based on Figure 5 from Garber and Gadirau. 1988)

Abbildung 11: Je schneller umso sicherer – Ergebnis eines Ensemblevergleichs in einer Studie von 1988

KI4Safety kann und soll nicht einen völlig neuen Ansatz liefern, sondern Hinweise darauf, wie sich die bestehenden Probleme besser kontrollieren lassen. Während das Problem, dass ein falsches Modell gewählt wurde, nur schwer zu lösen ist, kann man dem Problem des Ensembleansatzes (korrekte Spezifikation) durch den Aufbau einer geeigneten Datenbank entgegenwirken. Z.B. müsste man für jede der MaKaU Maßnahmen genügend Beispiele ähnlicher Verkehrsräume mit und ohne Behandlung finden um zu einer soliden Bewertung der verschiedenen Maßnahmen zu gelangen. Ein solcher Aufbau ist es, der in diesem Projekt prinzipiell demonstriert werden soll.

Etwas schwieriger ist das R2M Problem beim Vorher-Nachher-Vergleich: Unfallzahlen folgen einer Poisson oder einer negativen Binomialverteilung, das wurde auch in diesem Projekt einmal mehr bestätigt und auch mit konkreten Zahlen und Analysen hinterlegt (vgl. Meilensteinbericht 1). Das ist wie folgt zu verstehen: Montagmorgens in Berlin in der Stunde zwischen 8 und 9 Uhr gibt es im Durchschnitt 25 Unfälle. Ein Jahr hat 52 Wochen, daher hat man pro Jahr 52 Montagmorgens von 8 bis 9, und das ergibt das rote Histogramm (vgl. Abbildung 12).

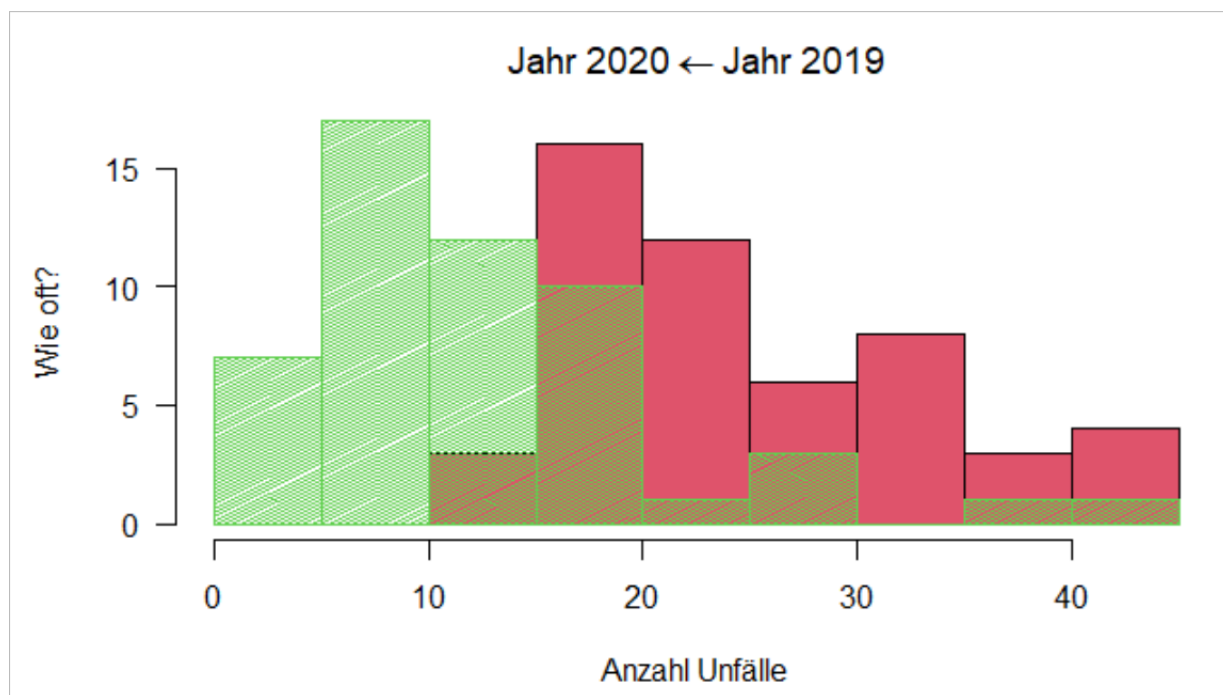


Abbildung 12: Simulierte Histogramme von zwei Unfallverteilungen, die einer negativen Binomialverteilung folgen. ($\mu = 25, \text{size} = 12$, 2019, rot und $\mu = 12.5, \text{size} = 4$, 2020, grün schraffiert).

In diesem Fall war es die fiktive Maßnahme „Covid19“. Hier haben wir angenommen, dass der induzierte Rückgang der Verkehrsleistungen die Unfälle in dieser Stunde halbiert hat: auf 12,5 Unfälle. In Abbildung 12 ist gut zu erkennen, wie breit die Verteilungen sind. Den R2M Effekt kann man aus dieser Gegenüberstellung der Verteilungen der Jahre 2019 und 2020 ausrechnen: der Mittelwert der roten Boxen ist 25,4, der Mittelwert der zehn schlechtesten Stunden aber 38,6. D.h. wenn man tatsächlich eine Folge von schlechten Montagen hat, dann wären im Mittel 38,6 Unfälle zu erwarten. Wenn man dann einfach nur abwartet, fällt die Unfallzahl ohne äußeres Zutun wieder auf den Mittelwert 25. Wenn man allerdings beide Verteilungen vergleichen kann, in diesem Beispiel die grüne und die rote, dann ist es leicht nachzuweisen, dass diese beiden tatsächlich verschieden sind. Auch die Effektgröße, in diesem Fall die Verringerung der Zahl der Unfälle um den Faktor zwei, lässt sich aus den empirischen Parametern der Stichproben mit geringerer Irrtumswahrscheinlichkeit berechnen.

Der Vergleich der Verteilungsparameter für große Stichproben ist daher ein guter Ansatzpunkt um tatsächlich viele der Nachteile eines Ensembleansatzes und eines Vorher-Nachher-Vergleiches auszuschalten.

2.6. Methodische Überlegungen zur statistischen Auswertung: Regression zur Mitte

Die übliche Vorgehensweise zur Bewertung der Wirksamkeit von Maßnahmen zur Erhöhung der Verkehrssicherheit ist der Vorher-Nachher Vergleich bei Umsetzung der Maßnahme (Maier et al., 2016). Man vergleicht die Unfallzahlen über drei Jahre gemittelt vor und nach Umsetzung der Maßnahme durch die Unfallkommission. Dies kann problematisch sein.

Wenn sich eine Unfallkommission (i) gezielt Unfallschwerpunkte heraussucht und (ii) Unfallhäufungen auch rein zufällig vorkommen, dann ist davon auszugehen, dass sich die Zahl der Unfälle auch ohne Umsetzung einer Maßnahme verringern wird, weil sie sowieso dem langjährigen Mittelwert entgegenstrebt.

Dies wird als Regression zur Mitte bezeichnet (Pauw et al., 2013). Bedingung (i) führt zu einem sogenannten Auswahlfehler. Der Auswahlfehler ist die Differenz zwischen einem festgestellten auffälligen Unfallgeschehen an einem Unfallschwerpunkt und einem langjährigen Mittelwert.

(Spahn, 2011) berücksichtigt den Auswahlfehler bei der Bewertung einer Maßnahme und erklärt eine Maßnahme erst dann als wirksam, wenn die Differenz im Vorher-Nachher Vergleich größer ist als der Auswahlfehler. Da die Unfallzahl an einer Unfallhäufungsstelle eine Zufallsgröße ist, darf auch dies als problematisch angesehen werden. Immer dann, wenn sich nach Einführung der Maßnahme zufällig höhere Unfallzahlen einstellen als im langjährigen Mittel, wird die Maßnahme – oft falsch – negativ als unwirksam klassifiziert.

Der übliche direkte Vorher-Nachher-Vergleich (Maier et al., 2016) ergibt also sehr optimistische Aussagen zur Wirksamkeit einer Maßnahme. Ein Herausrechnen des Auswahlfehlers (Spahn, 2011) ergibt dagegen sehr pessimistische Aussagen. Realistische Aussagen sind nur möglich, wenn man Häufigkeitsverteilungen von Unfällen vergleicht.

Der aktuelle Stand der Forschung zu Verkehrsunfällen vermutet (Lord & Mannering, 2010), dass diese einer negativen Binomialverteilung folgen. Diese diskrete Verteilung lässt sich mit Hilfe von zwei Parametern beschreiben, mit der sich das Verhältnis zwischen der Varianz und dem Mittelwert der Verteilung parametrieren lässt. Das ist eine Konsequenz der Beobachtung, dass Unfallverteilungen oft über-dispers sind, also eine Verteilung zeigen, bei der die Varianz größer ist als der Mittelwert.

Im Folgenden wird der hypothetische Fall von $N=1000$ Unfallhäufungsstellen (UH) betrachtet. Die Unfallrate wird mit einem Mittelwert von $\mu = 10$ Unfällen pro Intervall (das können z.B. die drei Jahre sein, die oft in Unfalluntersuchungen gewählt werden) angenommen, das Verhältnis zwi-

schen der Varianz σ^2 und dem Mittelwert mit $\frac{\sigma^2}{\mu} = 2$, die Verteilung folge einer negativen Binomialverteilung mit den Parametern $\mu=0.5$ und $\text{size}=10$ (Parametrisierung im Statistikprogramm R (R Core Team, 2019)).

In zwei aufeinander folgenden Perioden kann man dann die Verteilungen ermitteln (siehe Abbildung 13). Die Mittelwerte und Varianzen liegen bei $N=1000$ nahe bei den zu erwartenden Werten. Wenn man die $n=100$ schlechtesten „Orte“ aus der ersten Periode auswählt, dann ist deren Mittelwert aber viel größer als $\mu = 10$, es kommt heraus, dass in diesem Fall $\mu_{bS} \approx 22$ ist (abhängig von den gewählten Parametern). Das ist keineswegs überraschend, weil ja gerade die 100 schlechtesten herausgesucht wurden.

In der nächsten Periode folgen diese 100 Orte aber wieder der ganz normalen Verteilung, mit dem Mittelwert $\mu = 10$. Betrachtet man das hingegen aus der Brille einer Unfallkommission, und nimmt man weiter an, dass an diesen 100 Orten entsprechende Maßnahmen ergriffen wurden, dann hätte man eine durchaus beachtliche Reduktion der Unfallzahlen um 50% erzielt. Diese Reduktion hätte sich aber auch durch einfaches Zuwarten ergeben (konservativ-exspektative Strategie), ist somit kein Ergebnis der Maßnahmen, sondern schlicht ein Beispiel der Regression zur Mitte.




Abbildung 13: Verteilung der Unfälle bei einer angenommenen negativen Binomialverteilung in zwei aufeinander folgenden Betrachtungszeiträumen.

Der Effekt ist in der Literatur beschrieben (siehe (Pauw et al., 2013) und weitere Referenzen in diesem Artikel), aber naturgemäß schwierig zu quantifizieren, weil man die zugrundeliegenden Verteilungen nicht kennt und weil es eine Vielzahl an konkurrierenden Faktoren gibt, die ebenfalls zur Variabilität beitragen. Auch ist es eben alles andere als einfach, so große Fallzahlen wie in dem oben durchgespielten Beispiel in der Praxis zu studieren.

Um dieses Beispiel noch zu vollenden: hätte man an den 100 Kreuzungen eine Maßnahme ergriffen, die tatsächlich die Unfallzahlen halbiert, dann hätte man in diesem Fall den Wert $\hat{\mu}_{bs} \approx 5$ erwarten müssen, sprich die Unfallzahlen hätten sich vierteln müssen. Im Prinzip ist es also möglich, eine entsprechende Regression zur Mitte Effekt heraus zu rechnen, allerdings ist damit zu rechnen, dass so große Fallzahlen und so große Effektgrößen in der Realität selten zu erreichen sein werden. KI-gestützte Big-Data Analysen, wie sie im Rahmen von KI4Safety durchgeführt werden sollen, sind ein aussichtsreicher Ansatz um große Fallzahlen zu erreichen.

In einem zweiten Schritt wurde versucht, die dem DLR vorliegende Daten der Unfälle in Berlin von 2001 – 2016 auf diesen Effekt hin zu untersuchen. Dazu wurden aus der Datenbasis Unfälle extrahiert, die möglich artenrein sind, sprich dasselbe Unfalldiagramm aufweisen. Betrachtet man nur die häufigsten Kollisionsdiagramme so fällt in einigen der Daten ein Trend über die Jahre 2001 – 2016 auf, für den wir keine Erklärung haben – daher wurde ein Unfalldiagramm mit der Nummer 75 ausgewählt, das zumindest in dieser Betrachtungsweise keinen auffälligen Trend aufweist.




Abbildung 14: Anzahl Unfälle der 10 häufigsten Kollisionsdiagramme und ihre Verteilung über die Jahre 2001 – 2016 in Berlin. Das Kollisionsdiagramm 75 ist in der Grafik dargestellt.

Die Unfälle des Kollisionsdiagramms 75 (Auffahrunfälle) wurden danach räumlich gruppiert, um Unfallschwerpunkte zu finden. Diese Unfallschwerpunkte sind keine im klassischen Sinn wie sie von einer Unfallkommission identifiziert werden, sondern sind lediglich Orte im Raum an denen Unfälle häufiger vorkommen als anderswo. In Abbildung 15 findet sich eine graphische Darstellung dieser Verteilung.

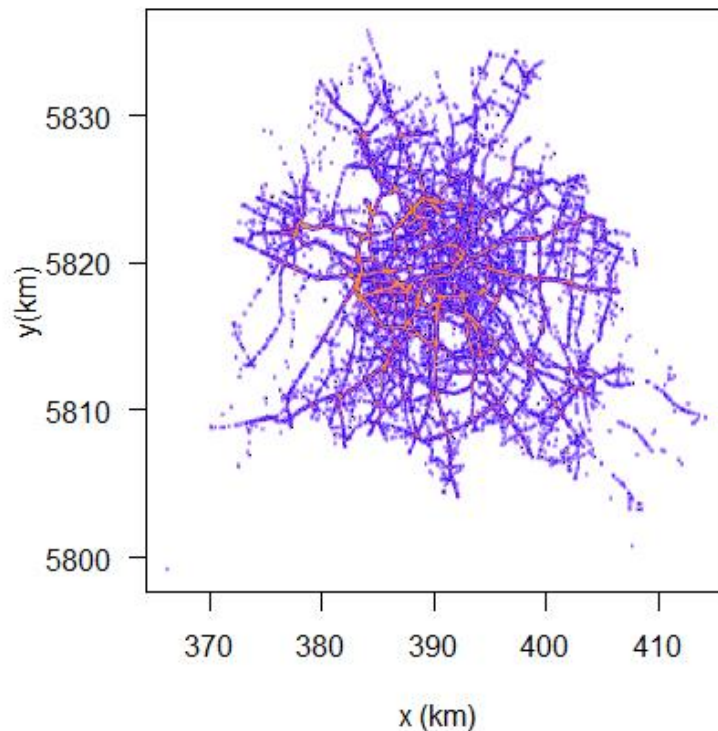


Abbildung 15: Verteilung der Unfälle des Kollisionsdiagramms 75 in Berlin. Für diese Darstellung wurde ein 80 x 80 m Raster gewählt, für die folgende Analyse wurden feinere Rasterungen verwendet.

Aus dieser Rasterung wurden dann die Orte identifiziert, in denen dieser Typ Unfall am häufigsten vorkam. In einem letzten Schritt wurden dann eine Diskretisierung der Zeit der Unfälle vorgenommen, damit daraus eine Zeitreihe der Anzahl Unfälle pro Zeitintervall berechnet werden konnte. Das gewählte Zeitintervall waren 100 Tage, diese Wahl ist aber willkürlich und kann an die Anzahl der tatsächlich vorhandenen Unfälle angepasst werden. Für diese Verteilung von Zahlen wurde dann mit einer negativen Binomialverteilung ein Fit durchgeführt.

Am Ergebnis ist bemerkenswert, dass sich für die 100 UH der Unfälle des Kollisionstyps 75 ergab, dass rund die Hälfte der UH weitgehend der Poissonverteilung genügen ($\frac{\sigma^2}{\mu} = 1$). Der übrige Teil, also wiederum die Hälfte wies tatsächlich ein Varianz-zu-Mittelwertverhältnis von größer als eins auf, so wie es nach aktuellem Stand der Forschung auch zu vermuten wäre (vgl. (Lord & Mannering, 2010)). Die Ergebnisse finden sich in Abbildung 16.




Abbildung 16: Varianz gegen Mittelwert für die 100 häufigsten Unfälle des Kollisionsdiagramms 75. Die beiden roten Linien sind die für $\frac{\sigma^2}{\mu} = 1$ und $\frac{\sigma^2}{\mu} = 2$.

Ausgehend von dieser Analyse scheint es möglich zu sein, die Größenordnung der Regression zur Mitte in Realdaten zu quantifizieren. Dies soll im Rahmen von KI4Safety näher untersucht werden.

2.7. Bedeutung von Sichtbehinderungen

Unzureichende Sichtbeziehungen an Knotenpunkten können zu gefährlichen Situationen und Unfällen führen. Gemäß (Pschenitzka, 2017) ist das „Übersehen anderer Verkehrsteilnehmer“ eine häufige Unfallursache beim Abbiegen und Einbiegen-/Kreuzen (Pkw als Hauptverursacher). In der ADAC-Studie wurden Sichtunfälle hinsichtlich der fahrzeugseitigen Einflussfaktoren (Sicht aus dem Fahrzeug heraus) und der Altersverteilung (ältere Fahrer ab 65 Jahren waren mehr als doppelt so oft Verursacher von Sichtunfällen im Vergleich zum Gesamtunfallgeschehen in Deutschland) tiefer untersucht.

Zu den infrastrukturellen Defiziten und Abweichungen von den technischen Regelwerken, die sich begünstigend auf Sichtunfälle auswirken können, gehören u.a. fehlende Sichtbeziehungen an Kno-

tenpunkten, insbesondere an Zufahrten sowie auch Einmündungen und Kreuzungen ohne Lichtsignalanlagen (Bergische Universität Wuppertal, 2014) . Sichtbehinderungen können auch durch ruhenden Verkehr, Werbetafeln, Verkehrsschilder und Straßenbegleitgrün entstehen. Aus diesem Grund ist z.B. gemäß ("Straßenverkehrs-Ordnung Vom 6. März 2013 (BGBl. I S. 367)" Neufassung Gem. V V. 6.3. 2013 I 367," 2013) das Parken vor und hinter Kreuzungen und Einmündungen bis zu fünf Meter von den Schnittpunkten der Fahrbahnkanten nicht zulässig.

Gemäß Beschluss (Deutscher Verkehrssicherheitsrat, 2016) werden die Kommunen und Länder aufgefordert, Maßnahmen zur Verbesserung der Verkehrssicherheit an Kreuzungen, Einmündungen und Zufahrten innerorts zu ergreifen. Bei diesen Maßnahmen wird u.a. die Einhaltung der Sichtbeziehungen genannt. Demnach soll speziell die Sicht von Wartepflichtigen auf den bevorrechtigten Verkehr (auch auf Fuß- und Radverkehr) gewährleistet werden. Zudem ist die Einhaltung von Sichtdreiecken bereits in der Entwurfsplanung sowie im Betrieb sicherzustellen bzw. die zulässige Höchstgeschwindigkeit des bevorrechtigten Verkehrs an die vorhandenen Sichtweiten anzupassen.

Die Überprüfung von Sichtbehinderungen erfolgt z.B. in der Entwurfsphase beim Planungsaudit sowie im Straßenbetrieb beim Bestandsaudit und bei Verkehrsschauen.

Aus Sicht des ADAC muss die erforderliche Sichtweite an Knotenpunkten den Verkehrsteilnehmern ermöglichen, rechtzeitig vor ein- und abbiegenden sowie kreuzenden Verkehrsteilnehmern zu halten (Hecht, 2017). Zudem dürfen sich in den Sichtfeldern für wartepflichtige Verkehrsteilnehmer nur erforderliche verkehrstechnische Anlagen (z.B. Lichtsignalanlagen, Lichtmasten) befinden. Diese Sichtfelder müssen von ständigen Sichtbehinderungen (Bewuchs, Hinweistafeln) befreit werden.

In der Bemessung der Sichtweiten für Knotenpunkte werden die Haltesichtweite, die Anfahrtssicht und die Annäherungssicht unterschieden. Für innerorts sind die Werte in der Richtlinie für die Anlage von Stadtstraßen (Forschungsgesellschaft für Straßen- und Verkehrswesen, 2007) festgelegt. An Grundstückszufahrten werden keine Anforderungen hinsichtlich erforderlichen Sichtfelder gestellt, wenngleich die Anfahrtssichtweite hier sicherlich analog zu Knotenpunkten von Relevanz sein dürfte.

Durch die erforderliche **Haltesichtweite** an untergeordneten Knotenpunktzufahrten (muss aus Gründen der Verkehrssicherheit immer nachgewiesen werden) können die Verkehrsteilnehmer rechtzeitig die Verkehrsregelung und Verkehrssituation auf der bevorrechtigten Straße erkennen und anhalten. Für Außerortsstraßen sind zudem die erforderlichen Haltesichtweiten für freie Strecken entsprechend der zulässigen Höchstgeschwindigkeit und der Längsneigung in (Forschungsgesellschaft für Straßen- und Verkehrswesen & Forschungsgesellschaft für Straßen- und Verkehrswesen, 2012) bestimmt.

Tabelle 3: Geschwindigkeitsgebote und Haltesichtweiten für untergeordnete Straßen

Zulässige Höchstgeschwindigkeit	Minimale Haltesichtweite
20 km/h	10 m
30 km/h	15 m
40 km/h	25 m
50 km/h	40 m
60 km/h	60 m
70 km/h	80 m

Minimale Haltesichtweite innerorts

Auch die **Anfahrtssichtweite** muss an untergeordneten Knotenpunktzufahrten gewährleistet sein: Im Abstand von drei Metern vor der Haltelinie bzw. vor dem Fahrbahnrand muss der Überblick über die bevorrechtigte Straße gegeben sein (siehe Tabellen 3 und 4). In diesem Sichtfeld sind keine Sichtbehinderungen durch z.B. Wegweiser oder Schutzplanken (höher als 0,75 Meter) erlaubt. Ggf. muss die zulässige Höchstgeschwindigkeit auf der übergeordneten Straße herabgesetzt werden.

Tabelle 4: Geschwindigkeitsgebote auf der übergeordneten Straße und Anfahr- bzw. Annäherungssichtweite

Zulässige Höchstgeschwindigkeit auf übergeordneten Straßen	Minimale Sichtweite
30 km/h	30 m
40 km/h	50 m
50 km/h	70 m
60 km/h	85 m
70 km/h	110 m
100 km/h	200 m




Abbildung 17: Erläuterung der Anfahrsichtweite

Das Sichtfeld für den Verkehrsteilnehmer auf der untergeordneten Straße 15 Meter vor der Haltelinie bzw. dem Fahrbahnrand (20 Meter bei hohem Schwerlastverkehrsanteil) ist als **Annäherungssichtweite** definiert (siehe Abbildung 17). Dadurch können Verkehrsteilnehmer ohne anzuhalten in die übergeordnete Straße einbiegen oder diese überqueren.

Bei einer maximal anzuordnenden zulässigen Höchstgeschwindigkeit von 70 km/h beläuft sich die erforderliche Sichtweite in die übergeordnete Straße jeweils auf 110 Meter nach rechts und links (siehe Abbildung 18). Bei ungünstigen Bedingungen können Zeichen 206 (Halt. Vorfahrt gewähren) oder Sichtblenden zum Erzwingen des Halts verwendet werden. Innerorts muss die Annäherungssicht nicht nachgewiesen werden.




Abbildung 18: Sichtfeld für den Verkehrsteilnehmer auf der untergeordneten Straße

An technisch nicht gesicherten Bahnübergängen (unbeschränkt, keine Lichtzeichen oder Blinklichter) werden die Sichtdreiecke durch den Kreuzungspunkt sowie den Sehpunkt und Sichtpunkt (abhängig von Geometrie, zulässiger Höchstgeschwindigkeit und Betriebsgeschwindigkeit) berechnet (siehe Abbildung 19).




Abbildung 19: Sichtbeziehungen am Bahnübergang



Abbildung 20: Erste Ergebnisse der semantischen Segmentierung in Google Street View Bildern

2.8. Messung von Sichtbehinderungen

Sichtbehinderungen haben großen Einfluss auf die Verkehrssicherheit. Kreuzungen, an denen die Sicht auf die umliegenden Straßen eingeschränkt ist, können zu Unfallhäufungspunkten werden. Aus diesem Grund legt der MaKaU einen besonderen Schwerpunkt auf Kreuzungen mit eingeschränkten Sichtverhältnissen. Zur Identifikation von Sichtbehinderungen aus Luft- und Befahrungsbildern mittels KI-Methoden sind verschiedene Überlegungen im Zuge von KI4Safety gemacht worden.

2.8.1. Sichtbehinderungen aus Sichtdreieck

Ein möglicher Ansatz ist die Berechnung der maximalen Sichtweite aus einem Sichtdreieck. Die Abstände zu Hindernissen sind in den Regelwerken vorgegeben, wodurch ein minimales Sichtdreieck aufzuspannen ist (vgl. Abbildung 21).

Um eine Sichtbehinderung aus einem Luftbild zu erfassen ist das maximale Sichtdreieck aufzuspannen. Aus diesem ist dann die maximale Sichtweite zu berechnen. Die Sichtweite ist darauf basierend auf die Richtlinienkonformität zu prüfen.




Abbildung 21: Aufspannen eines Sichtdreiecks aus einem Luftbild

Analog zu den Auswertungen aus einem Luftbild ist auch die Auswertung aus einem Befahrungsbild möglich. Auch hier ist ein Aufspannen des Sichtdreiecks möglich, sodass daraus die maximale Sichtweite errechnet werden kann (vgl. Abbildung 22).




Abbildung 22: Aufspannen eines Sichtdreiecks aus einem StreetView-Bild

Schwierigkeiten ergeben sich aus der exakten Winkel- und der daraus resultierenden Abstandsrechnung. Darüber hinaus zeigt ein Luftbild lediglich einen Blick von oben, sodass Hindernisse in Bezug auf ihre Höhe nicht geprüft werden können. Insbesondere bei der Befahrungsbild-Auswertung muss die künstliche Intelligenz wissen, was als störendes Element definiert ist und was die Sicht nur temporär verdeckt (bspw. ein fahrendes Kfz). Aus diesem Grund ist eine Verschneidung beider Bildquellen sinnvoll.

In Abbildung 23 ist zu erkennen, dass die Sicht aus größerer Distanz den Blick auf die querende Straße verdeckt. Die Sicht ist in diesem Bereich sehr eingeschränkt.



Abbildung 23: Aufbau eines Sichtrechtecks aus größerer Distanz

Gelangt man näher an den Kreuzungsbereich, ist das Foto als Panoramabild aufzunehmen um einen 180°-Bereich im Kreuzungsbereich zu untersuchen (vgl. Abbildung 24).



Abbildung 24: Aufbau eines Sichtrechtecks aus kürzerer Distanz (Blick nur in eine Richtung; optimal wäre 180° Bild)

Auch bei diesem Vorgehen gilt es verschiedene Besonderheiten bzw. Schwierigkeiten zu beachten. Der exakte Abstand von der Kamera des Befahrungsfahrzeugs bis zur relevanten Haltelinie ist genau zu bestimmen. Nur so lässt sich ein exaktes Sichtrechteck aufspannen. Gleichzeitig muss die Größe des Sichtrechtecks durch Tests kalibriert werden. Schlussendlich ist auch die KI derart anzulernen, dass sie unterscheiden kann, welche Hindernisse für die Sicht relevant sind und welche sich bspw. hinter der Straße aber innerhalb des Sichtrechtecks befinden.

2.8.2. Verfügbarkeit von Trainingsdaten

Die Erkennung von Hindernissen in Luftbildern kann grundsätzlich durch semantische Segmentierung erfolgen. Hierfür ist ein Trainingsdatensatz notwendig, wie z.B. der SkyScapes-Datensatz (Azimi et al., 2019). Frei verfügbar ist derzeit keiner der Datensätze. Die Erstellung eines projektspezifischen Trainingsdatensatzes ist aufgrund der begrenzten zeitlichen wie finanziellen Mittel im Rahmen des Projektes Ki4Safety nicht möglich. Daher ist es aktuell im Rahmen von Ki4Safety noch nicht möglich, eine semantische Segmentierung von Luftbildern durchzuführen.

2.8.3. Fazit

Aufgrund der beschriebenen Schwierigkeiten bei der Bestimmung der Kalibrierungsparameter der Kamera in den Befahrungsbildern sowie der mangelnden Verfügbarkeit von Trainingsdaten für die semantische Segmentierung von Luftbildern ist die Untersuchung der Sichtbeziehungen zunächst zurückgestellt worden. Der Aufwand, die erkannten Schwierigkeiten und Besonderheiten zu bewältigen wird als so hoch eingeschätzt, dass er den Rahmen des Projektes zeitlich und vom Budget her überschreitet. Aus diesem Grund wird der Fokus nicht auf die Berechnung der Sichtbeziehungen gelegt.

2.9. Zusammenfassung

Aufgrund der insbesondere zeitlich begrenzten Ressourcen im Projekt wurde entschieden in der Implementierung Sichtbehinderungen nicht weiter zu betrachten, sondern den Fokus auf die Erkennung von Mittelinseln und Verkehrsschildern zu legen.

Am Beispiel von Mittelinseln soll gezeigt werden, wie man durch effizientes Training mit vergleichsweise geringem manuellem Aufwand ein KI-System in die Lage versetzen kann, mit hoher Zuverlässigkeit relevante Merkmale in Luftbildern zu finden. Diese Vorgehensweise kann dann auf andere relevante Merkmale erweitert werden, wie z.B. rot eingefärbte Furten für Radfahrer oder Zebrastrifen für Fußgänger.

Verkehrsschilder geben Hinweise auf das Vorhandensein bestimmter Verkehrsführungen, welche lt. MaKaU einen Einfluss auf das Unfallgeschehen haben. Dies sind z.B. Linksabbiegeverbote (<https://makau.bast.de/massnahmen/114>), die Regelung einer abknickenden Vorfahrt (<https://makau.bast.de/massnahmen/123>), Kreisverkehre (<https://makau.bast.de/massnahmen/108>), Halteverbote (<https://makau.bast.de/massnahmen/338>) usw.

3. Implementierung

3.1. Erkennung von Verkehrszeichen

Eine große Zahl von Maßnahmen in MaKaU betrifft die Änderung von Verkehrsführungen. Verkehrsführungen werden häufig durch Verkehrszeichen geregelt. Die Überprüfung der Wirksamkeit von Maßnahmen durch die KI-basierte automatisierte Erkennung von Verkehrszeichen in Befahrungsbildern und das Verschneiden dieser Informationen mit den entsprechenden Unfallzahlen und weiteren Parametern, wie z.B. der durchschnittlichen täglichen Verkehrsstärke (DTV), ist daher eine aussichtsreiche Vorgehensweise.

So bezieht sich beispielsweise Maßnahme 114 auf eine Situation, in der Kfz bei starkem Gegenverkehr beim Linksabbiegen Fußgänger oder Radfahrer übersehen (vgl. Abbildung 6). Empfohlen wird die Einführung eines Abbiegeverbotes. Sowohl Vorher-Nachher-Vergleiche als auch Ensemble-Vergleiche können nun für ähnliche Verkehrsräume durchgeführt werden, an denen ein solches Abbiegeverbot (Verkehrszeichens Z214-20 StVO) auftritt bzw. nicht auftritt unter der Bedingung, dass die DTV hohe Werte annimmt. Dabei muss gezielt auf die Häufigkeit von Unfällen geschaut werden, an denen Radfahrer und Fußgänger beteiligt sind.

Eine weiteres Beispiel ist Maßnahme 123 (Abbildung 25). Hier muss von der KI u.a. die Beschilderung Zeichen 306 mit Zusatzschild Z 1002 „Abknickende Vorfahrt“ erkannt werden.

Abknickende Vorfahrt aufheben

Defizit(e)

der Abbiegende
(Geradeausfahrt) begriff die
Vorfahrtregelung nicht,
mangelnde Markierung



Abbildung 25: MaKaU Maßnahme 123 – Abknickende Vorfahrt aufheben, wenn sie vom Geradeausfahrenden nicht begriffen wird

Nach Stand von Wissenschaft und Technik ist die Erkennung von Verkehrszeichen durch KI in Befahrungsbildern ein gelöstes Problem. Die in Benchmarks erzielten Erkennungsraten sind mit 98,97% Trefferquote sogar etwas besser als beim Menschen mit 98,81% (man spricht von superhuman Performance) (Sermanet & LeCun, 2011). Für die praktische Umsetzung besteht die Notwendigkeit, Trainingsdaten zur Verfügung zu haben.

3.1.1. Trainingsdatensätze

Folgende Datensätze sind aus der Literatur bekannt:

- German Traffic Sign Detection Dataset (GTSD) (Houben et al., 2013)
 - 900 Bilder (600 Trainingsbilder und 300 Testbilder) von deutschen Straßen
 - 43 Typen von Verkehrszeichen
- DFG Traffic Sign Dataset (DFGTS) (Tabernik & Skočaj, 2019)
 - 5.254 Trainingsbilder und 1703 Testbilder aus Slowenien
 - 200 Typen von Verkehrszeichen
- DFG Traffic Sign Augmented Dataset
 - DFGTS + abgeschnittene Instanzen von Verkehrszeichen zusammengeführt mit dem Belgischen Traffic Sign Dataset
 - DFGTS + zusätzlich 8775 Bilder
 - 200 Typen von Verkehrszeichen
- Datensatz der Tsinghua Universität (Zhu et al., 2016)
 - Mehr als 100.000 Befahrungsbilder
 - 30.000 Annotationen von Verkehrszeichen
 - Nur chinesische Verkehrszeichen
- Mapillary Traffic Sign Dataset (MTSD) (Ertler et al., 2019):
 - Befahrungsbilder aus der ganzen Welt.
 - 313 Typen von Verkehrszeichen
 - 257.543 Verkehrszeichenannotationen von denen 82.724 klassifiziert sind

Während der Evaluierung der genannten Trainingsdatensätze hat sich herausgestellt, dass im GTSD-Datensatz sehr viele fehlerhafte Annotierungen enthalten waren. Zu Beginn der Arbeiten an der Verkehrszeichenerkennung war zudem der Datensatz von Mapillary noch nicht verfügbar. Gute Ergebnisse konnten mit dem slowenischen DFGTS Datensatz erzielt werden.

Dabei hat es sich gezeigt, dass die frei verfügbaren Befahrungsbilder von Google Street View sehr weitwinklige Aufnahmen sind und starke Verzerrungen aufweisen. Auf diesen Bildern war die Erkennungsquote zunächst schlecht. Daraufhin wurde die Einleseroutine so verändert, dass Bilder mit einem geringeren Kamera-Öffnungswinkel von Google Street View eingelesen wurden. Bei einem Öffnungswinkel von 45° stellten sich dann gute Ergebnisse ein. Daher wurde die Bildaufnahme so verändert, dass von jedem Aufnahmepunkt überlappende Bilder in verschiedenen Richtungen entlang der Straße eingelesen wurden und auf diesen dann die Erkennung stattfand (vgl. Abbildung 26).



Abbildung 26: Panorama aus Google Street View zerlegt in Einzelbilder mit 45° Öffnungswinkel

3.1.2. Netzarchitektur

Aufgrund der aus der Literatur bekannten Leistungsdaten für Aufgaben der Objektdetektion wurde die Faster RCNN (Ren et al., 2017) Meta Architektur auf einer Resnet101 (Chollet, 2017) Basis ausgewählt. Die Faster-RCNN Meta-Architektur ist ein zweistufiger Ansatz: Es gibt eine Merkmalsextraktionsebene und eine Ebene zur Generierung der Umrandungsboxen für die erkannten Objekte. Erstere extrahiert die relevanten Merkmale im Bild mittels Faltungsmasken, deren Gewichte im Verlauf des Trainings angelernt werden.

Die extrahierte Merkmalskarte (Feature-Map) wird der zweiten Stufe zugeführt, die aus einer sogenannten ROI-Pooling-Schicht, Klassifizierungs- und Regressionsköpfen besteht.

Die ROI-Pooling-Schicht nutzt die extrahierte Feature-Map aus der ersten Stufe als Eingabe, um für gleichmäßig über das Bild verteilte sogenannten Ankerboxen zu bestimmen, wie wahrscheinlich es ist, dass sie ganz allgemein ein Objekt enthalten – z.B. ein Verkehrsschild. Nur die aussichtsreichsten Objektkandidaten werden dann an die Klassifizierungs- und Regressionsköpfe weitergegeben. Ziel des Klassifizierungskopfes ist festzustellen, welches Verkehrszeichen genau in der Ankerbox enthalten sein könnte. Da das Ergebnis der Klassifizierung Einfluss auf die Proportionen der Objektumrandung hat, wird mit dem Ergebnis der Klassifizierung eine passende, Ankerbox mit für diese Klasse passenden Proportionen gewählt. Schließlich werden die genauen Maße der Umrandungsbox mittels eines Regressionskopfes geschätzt, welcher wiederum die Ausgabe der Feature-Map als Eingangsdaten verarbeitet.

Resnet101 umfasst insgesamt 101 Extraktionsmasken verschiedener Größe und erzeugt damit genauso viele Feature-Maps während der Merkmalsextraktion. Diese Architektur gehört zu den aufwändigsten und leistungsfähigen Verfahren die derzeit üblich sind. Lediglich Resnet152 ist mit 51 zusätzlichen Extraktionsmasken noch aufwändiger. In den Experimenten hat sich jedoch gezeigt, dass die Ergebnisse mit Resnet152 nicht besser wurden.

Im Training zeigte sich, dass die Konvergenz gut ist und nach 70.000 Iterationen eine mittlere Erkennungsquote von 81% auf den Testdaten erreicht wird (vgl. Abbildung 28). Als Grenzwert für die Erkennung wurde eine Überlappung von 50% Intersection over Union (IOU), auch als Jaccard-Koeffizient bezeichnet, gefordert.




Abbildung 27: Meta Architektur Faster RCNN

Losses/TotalLoss




Abbildung 28: Konvergenz der Fehlerfunktion des Netzes beim Training auf dem DFGTS Trainingsdatensatz

3.1.3. Ergebnisse

Im Vergleich zur mehr als 98% Erkennungsquote im Benchmark ist die erzielte Erkennungsleistung von 81% auf dem Trainingsdatensatz vergleichsweise gering. Bei genauerer Betrachtung zeigt sich,

dass die Erkennungsleistung vom Abstand zwischen Kamera und Verkehrszeichen abhängt. Weiter entfernte Verkehrszeichen werden erwartungsgemäß seltener erkannt als Verkehrszeichen, die direkt vor der Kamera stehen (vgl. Abbildung 26). Netzarchitekturen mit besserer Erkennungsleistung weisen besondere Merkmale für eine bessere Erkennungsleistung bei verschiedenen Objektgrößen auf, z.B. mittels Multiskalenanalyse (Sermanet & LeCun, 2011).

Da die Verkehrszeichen bei den Befahrungsbildern mehrmals und in verschiedenen Skalen fotografiert vorkommen, bringt der Einsatz eines Netzes mit Multiskalenanalyse keine Vorteile. Bei der Durchsicht der Ergebnisse kann festgestellt werden, dass alle Verkehrszeichen pro Kreuzung erkannt werden und eine weitere Verbesserung der Erkennungsleistung des Netzes keine Verbesserung der Trefferquote in der Datenbank erwarten lässt.

In den Befahrungsdaten sowohl von Berlin als auch von NWSIB (Straßen.NRW) traten dennoch fehlerhafte Klassifikationen von Verkehrszeichen auf (vgl. Abbildung 29). Immer dann, wenn ein Verkehrszeichen in den Trainingsdaten nicht enthalten war, wurde das dazu ähnlichste Verkehrszeichen, welches in den Trainingsdaten vorhanden war, irrtümlich erkannt.



Abbildung 29: Erkennungsfehler wegen fehlender Klasse in den Trainingsdaten: Statt dem Linksabbiegegebot wurde ein Geradeausfahrverbot (DFGTS:II-46.2) erkannt

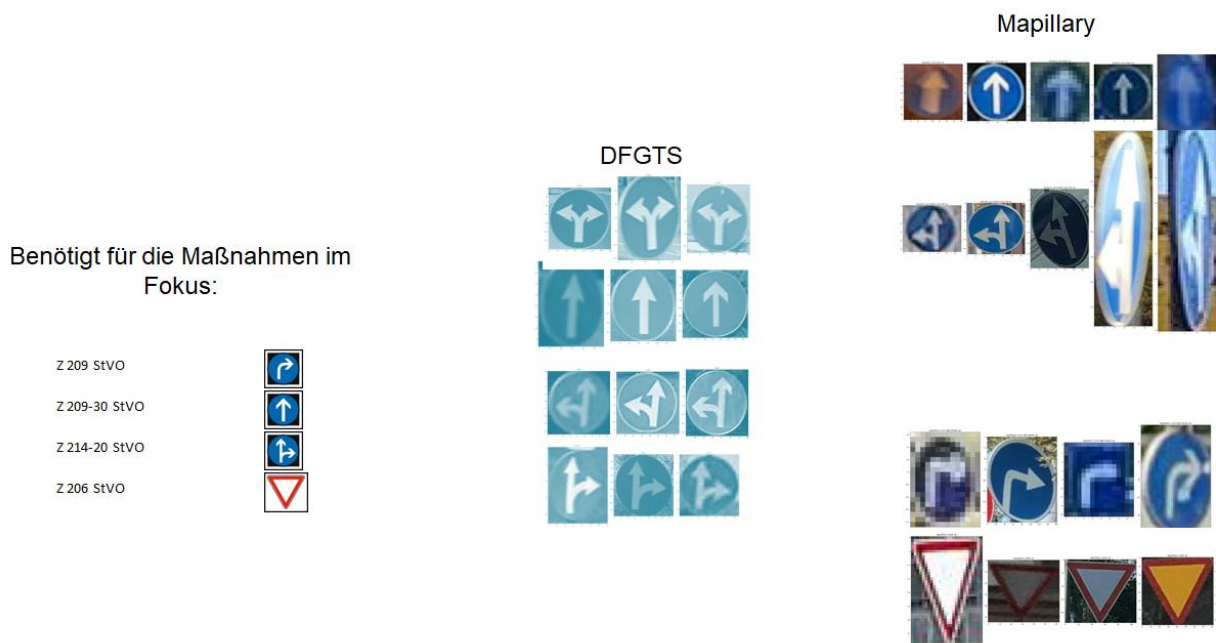


Abbildung 30: Für die Maßnahmenbewertung notwendige und in den Trainingsdaten verschiedener Trainingsdatensätze vorhandene Verkehrsschilder

In Abbildung 28 ist anhand eines Beispiels zu sehen, dass sich Algorithmen zur Erkennung von Verkehrsschildern täuschen lassen. Dies bedeutet, dass man einen Deep Learning Algorithmus nutzen kann, um Stichproben zu generieren und bestimmte Beschilderungen zu finden. Eine manuelle Überprüfung der Stichprobe ist dennoch angezeigt. Für die manuelle Prüfung wurde eine Softwarelösung für die Sichtung der Geo-Datenbank entwickelt, welche es ermöglicht Luft- und Befahrungsbilder effizient durchzusehen und Stichproben zu überprüfen.



Abbildung 31: Fehler bei der Erkennung von Verkehrsschildern.

3.1.4. Fazit und Ausblick

Die Verkehrszeichenerkennung in Befahrungsbildern funktioniert bereits mit Standardverfahren gut. Jedoch muss eine gute Trainingsdatenbasis vorhanden sein, die alle interessierenden Verkehrszeichen als unterschiedliche Objektklassen enthält.

Künftige Aktivitäten in KI4Safety konzentrieren sich auf folgende Themen:

- Zusammenführung der Trainingsdatensätze zur Verkehrszeichenerkennung von DFGTS und Mapillary zu einem gemeinsamen Datensatz (vgl. Abbildung 30).
- Nutzung von Domain-Adaptation Techniken um die Generalisierfähigkeit des Netzes zu verbessern, beispielsweise die Methode des unüberwachten Lernens, welche im kommenden Abschnitt vorgestellt wird.

3.2. Erkennung von Mittelinseln

Mittelinseln und Fahrbahnteiler können i.d.R. gut in Luftbildern erkannt werden. Da Luftbilder, im Gegensatz zu Befahrungsbildern für den Zeitraum zwischen 2000 und 2019 häufiger aufgenommen wurden, ist es zudem hiermit möglich, Vorher/Nachher Vergleiche durchzuführen. Hierzu werden Luftbilder verschiedener Jahre miteinander verglichen und im Hinblick auf die Umsetzung entsprechender Maßnahmen (z.B. Einbau von Fahrbahnteilern) analysiert. Durch einen Vergleich der

zugehörigen Unfallzahlen können dann Schlüsse über die Wirksamkeit der durchgeführten Anpassungen generiert werden.

Mittelinseln sind innerhalb der MaKaU Maßnahmen ein relevantes Merkmal. Dieses Merkmal ist in Luftbildern aus Google Maps oder Google Earth erkennbar und somit steht eine breite Datenbasis zur Verfügung (vgl. Abbildung 32).

Für die Erkennung von Mittelinseln wurde eine Deep-Learning Architektur entwickelt, welche für ein gegebenes Luftbild entscheiden kann, ob eine Mittelinsel vorhanden ist oder nicht.



Abbildung 32: In den Trainingsdaten enthaltene Beispiele für Mittelinseln in Luftbildern

Die Entwicklung dieses Ansatzes beinhaltete drei hauptsächliche Schritte:

1. Erstellung einer initialen Datenbasis
2. Entwicklung und Training der Architektur
3. Entwicklung von Strategien um die limitierte Datenbasis zu kompensieren

3.2.1. Erstellung der initialen Datenbasis

Im Rahmen von KI4Safety wurden durch manuelle Auswertung von Luftbildern insgesamt 39 Fahrbahnteiler und Mittelinseln in Baden-Württemberg ermittelt, welche als Trainingsdaten genutzt werden sollen, um einen Detektor für Fahrbahnteiler zu realisieren. Darüber hinaus wurden in Hessen, Bayern und Baden-Württemberg insgesamt 385 weitere Fahrbahnteiler per Google-Earth Luftbild identifiziert und zu Trainingszwecken zur Verfügung gestellt.

Des Weiteren wurde dokumentiert, in welchen Zeiträumen bauliche Veränderungen festgestellt werden konnten, welche nach MaKaU relevant sind (siehe auch Anlage 3 und Abbildung 33).




Abbildung 33: Auszug aus den Trainingsdaten für die Erkennung von Mittelinseln in Luftbildern

Dieser Datensatz war bereits zum Training der KI verwendbar, aber noch zu klein, was sich darin äußerte, dass die Erkennungsergebnisse häufig falsch waren. Da es sich gezeigt hatte, dass die manuelle Erweiterung dieses Datensatzes arbeitsaufwändig ist, wurde ein weiterer Weg zur Trainingsdatengewinnung erprobt.

Die Erstellung dieser Trainingsdatenbasis erfolgte durch eine Kombination von Google Maps und Open Street Maps. Dabei wurden als Trainingsbilder Luftbilder der Kreuzungen aus Google Maps extrahiert, welche Mittelinseln enthielten. Die Information, ob in einem Luftbild eine Mittelinsel vorhanden ist kam dabei aus Open Street Maps. Open Street Maps beinhaltet jedoch nur für eine geringe Anzahl an Kreuzungen die Information, ob hier eine Mittelinsel vorhanden ist oder nicht. Für die Gebiete von Nordrhein-Westfalen und Berlin konnten auf diese Art und Weise 2.700 Luftbilddaten als Trainingsdaten gewonnen werden.

Aus diesem Datensatz wiederum wurden 271 Bilder für einen Validierungsdatsatz und 271 Bilder für einen Testdatsatz entnommen. Validierungs- und Testdatsatz beinhalten Daten, welche das Netzwerk während des Trainings nicht sieht. Diese können dafür verwendet werden, die Generalisierungsperformance des Neuronalen Netzwerkes zu untersuchen. Der Validierungsdatsatz dient dabei dazu Effekte wie Overfitting zu erkennen und allgemein das Modell auszuwählen, welches am besten auf noch nicht gesehenen Daten funktioniert. Da dies jedoch implizit eine Optimierung des Netzes für den Validierungsdatsatz darstellt, wird zusätzlich die Genauigkeit auf einem

Testdatensatz bestimmt. Dies geschieht dann, um ein abschließendes Bild über die Leistung des Netzwerkes auf neuen Daten zu bestimmen.

3.2.2. Entwicklung und Training der Architektur

Als Basisarchitektur für das Klassifikationsnetzwerk wurde ein InceptionResNetV2 (Szegedy et al., 2017) gewählt, da dieses auf gängigen Bildklassifikations-Benchmarks unter den besten Netzwerken liegt. Darüber hinaus handelt es sich hierbei um ein sehr tiefes Netzwerk, was z.B. einem Overfitting bei zu wenigen Daten vorbeugt. Overfitting bedeutet, dass das Netz bestimmte Formen von Mittelinseln „auswendig lernt“, wodurch letztlich eine schlechte Erkennungsleistung für Mittelinseln zu erwarten wäre, welche das Netz vorher noch nie gesehen hat.

Die vom Merkmalsextraktor (vgl. Abbildung 34: Feature Extractor) generierte Feature Map dient dann wiederum einer Reihe an Fully Connected Layern als Eingabe, welche den Klassifikator bilden. Ausgabe des Klassifikators ist die Information, ob eine Verkehrsinsel im Bild erkannt wurde oder nicht. Zum Training wurde diese Architektur verwendet und mit auf dem ImageNet Datensatz vor-trainierten Gewichten initialisiert. Hierbei wurde ein ADAM Optimierer (Kingma & Ba, 2014) mit einer Lernrate von 0,0001 für den Trainingsprozess verwendet. Aus dieser Konfiguration ergab sich eine Erkennungsgenauigkeit im Training von 99%, eine Validierungsgenauigkeit von 87,08%, eine Testgenauigkeit von 86.35%.

Die Tatsache, dass die Erkennungsleistung auf dem Trainings-Datensatz so viel höher war als die auf den Datensätzen, die das Netz vorher nicht gesehen hat, ließ darauf schließen, dass das CNN schlecht generalisiert bzw. verallgemeinert. Dies zeigte sich auch bei der Durchführung eines Erkennungslaufes (Inferenz) auf der großen Datenbasis wieder, welche zum Aufbau der Datenbank verwendet werden sollte. Mögliche Gründe hierfür sind, dass die Trainingsdatenverteilung keine gute Repräsentation der tatsächlichen Verteilung ist. Aus einer zu geringen Anzahl an Trainingsdaten folgt zudem, dass der gelernte Feature Extractor keine gut generalisierende Feature-Map generiert.




Abbildung 34: Aufbau des Erkennungsalgorithmus

3.2.3. Strategien um die limitierte Datenbasis zu kompensieren

Um dem Problem der unzureichenden Generalisierung durch das Netz entgegenzuwirken wurden im dritten Schritt Methoden des selbst überwachten Lernens (Self Supervised Learning) und der

Detektion von Grenzfällen (Corner Case Detection) angewendet. Mit Self Supervision kann erreicht werden, dass der Feature Extractor des CNNs so trainiert werden kann, dass die sich ergebenden Feature Maps gut generalisieren. Dabei wird der Feature Extraktor mit Surrogat-Aufgaben trainiert, welche während des Trainings Merkmale erzeugen, die auch für die tatsächliche Klassifikationsaufgabe der Verkehrsinselklassifikation relevant sind. Diese Surrogat-Aufgaben haben dabei die Eigenschaft, dass man sie automatisch annotieren kann.

Mithin kann man auf allen zur Verfügung stehenden (auch nicht annotierten) Daten trainieren, was zu einer guten Generalisierungsfähigkeit führt. Eine automatisch generierte Surrogat-Aufgabe, welche hierfür verwendet wurde, kann man in der Abbildung 35 sehen. Dabei wird randomisiert aus einem Bild ein Ausschnitt kopiert und an einer zufälligen Position im selben Bild wieder eingefügt. Die Aufgabe auf die das Netzwerk trainiert wird, ist dann zu bestimmen, woher der kopierte Ausschnitt ursprünglich stammt.

Das Resultat des hier beschriebenen Ansatzes zur Verbesserung der Generalisierungsleistung ist ein Genauigkeitsgrad von 94,73 % auf dem Validierungsdatensatz und ein Genauigkeitsgrad von 95,2% auf dem Testdatensatz. Dies bedeutet, dass die Häufigkeit von Fehlern auf dem Validierungsdatensatz um 51,39% und auf dem Testdatensatz um 64,83% verringert werden kann.




Abbildung 35: Aufgabe im selbstüberwachten Lernen: Das neuronale Netz soll feststellen, aus welchem Teil des Bildes ein Bildausschnitt entfernt wurden.

Bei Verfahren der Corner Case Detektion handelt es sich um Ansätze, welche dazu dienen in großen nicht annotierten Datenmengen solche Datenpunkte zu identifizieren, welche noch nicht in der ursprünglichen Trainingsdatenmenge repräsentiert sind. Die Annotation solcher Datenpunkte führt dann zu einer stärkeren Verbesserung als die Annotation randomisiert ausgewählter Datenpunkte. Als Maß für eine derartige epistemische Unsicherheit wurden in diesem Fall das Monte Carlo Dropout Verfahren verwendet. Dabei wird während der Inferenz randomisiert ein bestimmter Anteil der Neuronen des Neuronales Netzwerkes abgeschaltet. Dieser Vorgang wird in unserem Fall 500 Mal wiederholt.

In jedem Durchlauf generiert das Netzwerk dabei Konfidenzwerte für die Klassen „Mittelinsel vorhanden“ und „Mittelinsel nicht vorhanden“, sodass am Ende 500 Konfidenzwerte für beide Klassen vorliegen. Hieraus lassen sich dann wiederum ein Mittelwert und eine Standardabweichung bestimmen, welche kombiniert als ein Maß für die Unsicherheit des Netzwerkes verstanden werden können. Auf Basis dieses Maßes wurden dann solche Datenpunkte gezielt nachträglich annotiert,

welche einen großen Unsicherheitswert aufwiesen. Zusätzlich wurden Datenpunkte mit der geringsten Unsicherheit auf ihrer Richtigkeit überprüft, um mögliche strukturelle Probleme in der Trainingsdatenbasis zu finden.

Die Verbesserungen des Trainings des Neuronalen Netzwerkes zur Klassifikation von Verkehrsinseln in Luftbilddaten ergaben ein System, welches verwendet wurde um die Merkmalsdatenbank für die Bundesländer Nordrhein-Westfalen und Berlin mit Daten über das Vorhandensein einer Mittelinsel aufzufüllen. Mithin ist eine Datenbasis entstanden, welche für eine Studie zur Validierung von MaKaU-Maßnahmen geeignet erscheint, in denen die Einführung einer Mittelinsel empfohlen wird.

3.3. Aufbau der Datenbank

Die zur Analyse verwendeten Bilddaten und ebenso die Analyseergebnisse werden in einer zentralen Datenbank abgespeichert.

Es wird ein relationales Datenbankmodell verfolgt, bei welchem die Objekte voneinander abhängig sind. Jedem Objekt einer Kreuzung können somit verschiedene Parameter in Form von Tabellen gegeben werden. Für jede Kreuzung werden, falls sie vorhanden sind, die folgenden Daten aufgenommen: Luft- und Befahrungsbilder, Verkehrszeichen, bauliche Eigenschaften, Verkehrsunfälle sowie Wetterlage und Verkehrsstärke im Zeitraum der entsprechenden Unfallereignisse.

Die Daten hierfür werden entweder von Drittanbietern heruntergeladen oder eigenständig generiert. Luft- und Befahrungsbilder können aus den Google-Datensätzen über eine Schnittstelle abgerufen werden und stehen für die Analysen, z.B. der Erkennung von Verkehrszeichen und Mittelinseln bereit.

Diese Daten können jedoch auch teilweise von den jeweiligen Bundesländern oder anderen Anbietern bezogen werden. Aktuell liegen Befahrungsbilder aus Nordrhein-Westfalen und Unfalldaten aus den Bundesländern Nordrhein-Westfalen (vgl. www.nwsib-online.nrw.de) und von Berlin vor. Zur Erstellung des Datenbankschemas (vgl. Abbildung 36) wurden die relevanten Objekte ermittelt und anschließend in eine Normalform überführt. In dieser Form sind die einzelnen Attribute der Objekte in Tabellenspalten in verschiedenen Tabellen enthalten und um Redundanzen bereinigt. Durch diese Vorgehensweise wird einerseits weniger Speicherplatz verbraucht und andererseits wird die Konsistenz der Daten gewahrt.

So entstehen bspw. aus den Unfalldaten mehrere Tabellen, die jeweils ein bestimmtes Attribut abbilden.

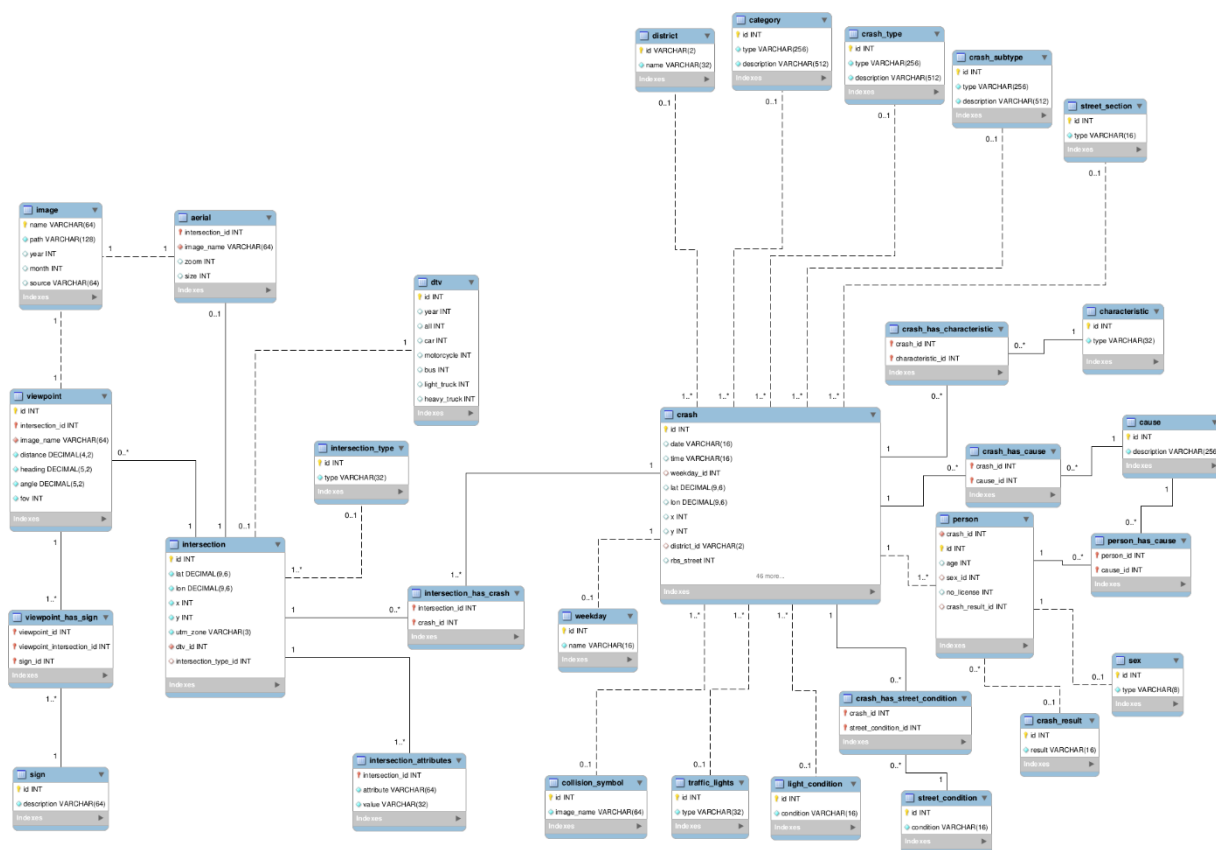


Abbildung 36: Datenbankschema KI4Safety

Das Eingliedern der Daten wird mithilfe von Skripten automatisiert durchgeführt. Dafür wird unter der Programmiersprache Python die Bibliothek *mysql-connector* verwendet, mit der mit einer MySQL-Datenbank kommuniziert werden kann.

Zuerst muss das Format eines Datensatzes bestimmt werden, sofern es nicht bereits bekannt ist. Die Daten werden dem Format entsprechend ausgelesen und können anschließend über ein Insert-Statement in die Datenbank geschrieben werden. Ein solches Statement wird in SQL verfasst und kann bspw. die folgende Form haben:

```
INSERT INTO crash (id, date, time) VALUES (54, „03.10.2005“, „18:46“)
```

Für spätere Abfragen an die Datenbank werden Statements in einer ähnlichen Weise formuliert. Die unterschiedlichen Daten (Luft- und Befahrungsbilder, Unfälle, Verkehrsstärke, usw.) sind in jeweils unterschiedlichen Formaten abgespeichert. Somit muss für jeden Datensatz auch ein neues Skript zum Einfügen verfasst werden.

Diese Skripte folgen jedoch immer demselben Aufbau: Zuerst werden die Daten aus der Datei gelesen. Ist diese im CSV-Format (Comma Separated Values) kann die Datei direkt mit Python verarbeitet werden. Für Dateien die kodiert oder komprimiert sind existieren häufig bereits Implementierungen in Form einer für Python kompatiblen Bibliothek. Die gelesenen Daten können entweder zeitgleich oder erst nachdem diese gelesen wurden in die Datenbank übertragen werden. Zur effizienten Nutzung des Arbeitsspeichers ist eine zeitgleiche Verarbeitung notwendig.

Für das Einfügen der Daten in die Datenbank wurde ein Skript geschrieben, welches den Prozess deutlich vereinfacht. Es beinhaltet bereits Standardfunktionen zum Verbinden, Erstellen von Statements, Ausführen von Statements und Überprüfung von Werten. Diese Funktionen können in den auf die Daten angepassten Skripten verwendet werden.

Die Datenbank wurde schrittweise mit den einzelnen Datensätzen befüllt. Aufgrund der Größe dieser Daten erwies sich dieser Prozess als zeitlich sehr aufwändig und benötigte mehrere Monate. Im aktuellen Entwicklungsstand sind folgende Skripte enthalten (vgl. **Tabelle 5**):

Tabelle 5: Skripte zur Datenanalyse und Befüllung der Datenbank

Script	Funktion
crash_intersection_linker.py	Verknüpfung von zusammengehörigen Kreuzungen und Unfällen
crash_insert.py	Auslesen der Unfalldaten und Einfügen in die Datenbank
database.py	Kommunikation zur Datenbank
image_comparison.py	Ermittlung der Blickrichtung für die rektifizierten Google StreetView Bilder mithilfe von Panoramabildern
nwr_extract.py	Ermittelt alle relevanten Befahrungsbilder aus dem NRW-Datensatz (diejenigen die sich an Kreuzungen befinden)
osm_analyzer.py	Analysiert OSM-Dateien einer bestimmten Region auf ihre Kreuzungen
sample_generator.py	Generierung von Luft- und Befahrungsbildern für angegebene Kreuzungen und Einfügen der Bilder und Kreuzungen in die Datenbank
traffic_island_insert.py	Einfügen der Ergebnisse aus der Detektion der Verkehrsinseln in die Datenbank

3.4. Datenextraktion mittels OpenStreetMap und Google Street View

Es wurden Python-Skripte mit folgenden Funktionalitäten realisiert (vgl. Abbildung 37):

- Extraktion von Kreuzungspunkten aus der OpenStreetMap (OSM) Datenbank
- Extraktion von Ansichten der Kreuzungspunkte aus den Zufahrten heraus aus Google Street View

Mit Hilfe dieser Skripte kann eine Tabelle mit allen Kreuzungspunkten erstellt werden, die in einer geografischen Region vorhanden sind. So wurden beispielsweise für das Stadtgebiet von Berlin 8.324 Kreuzungspunkte ermittelt und dazu 23.581 Ansichten generiert.



Abbildung 37: Automatisch extrahierter Datensatz bestehend aus Luftbild und Ansichten aus den Seitenarmen heraus

4. Evaluierung

4.1. Durchführung einer Studie: Workflow

Zur Erstellung und Bearbeitung von Stichproben wurden anfangs Machbarkeitsuntersuchungen zu verschiedenen Lösungsansätzen durchgeführt. Neben einer MySQL-Datenbank wurde alternativ auch der Ansatz getestet, die Daten in einer PostGIS (<https://de.wikipedia.org/wiki/PostGIS>) Datenbank abzulegen.

Um sicherzustellen, dass die Projektergebnisse über das Projektende hinaus gepflegt und weiterentwickelt werden können, wurde die Traffic Data Plattform (Tcheumadjeu et al., 2010) gewählt, welche projektübergreifend beim DLR Institut für Verkehrssystemtechnik zum Einsatz kommt.

Als Front-End wurde zunächst eine Web-Applikation (<https://de.wikipedia.org/wiki/Webanwendung>) getestet. Damit war es möglich, grundlegende Filteroperationen zu implementieren (vgl. Abbildung 38). Es stellte sich aber bald heraus, dass der Implementierungsaufwand für die erforderliche Funktionalität der Erstellung und Bearbeitung von Stichproben den Budgetrahmen von KI4Safety sprengen würde. Daher wurde der Lösungsansatz Web-App wieder verworfen.

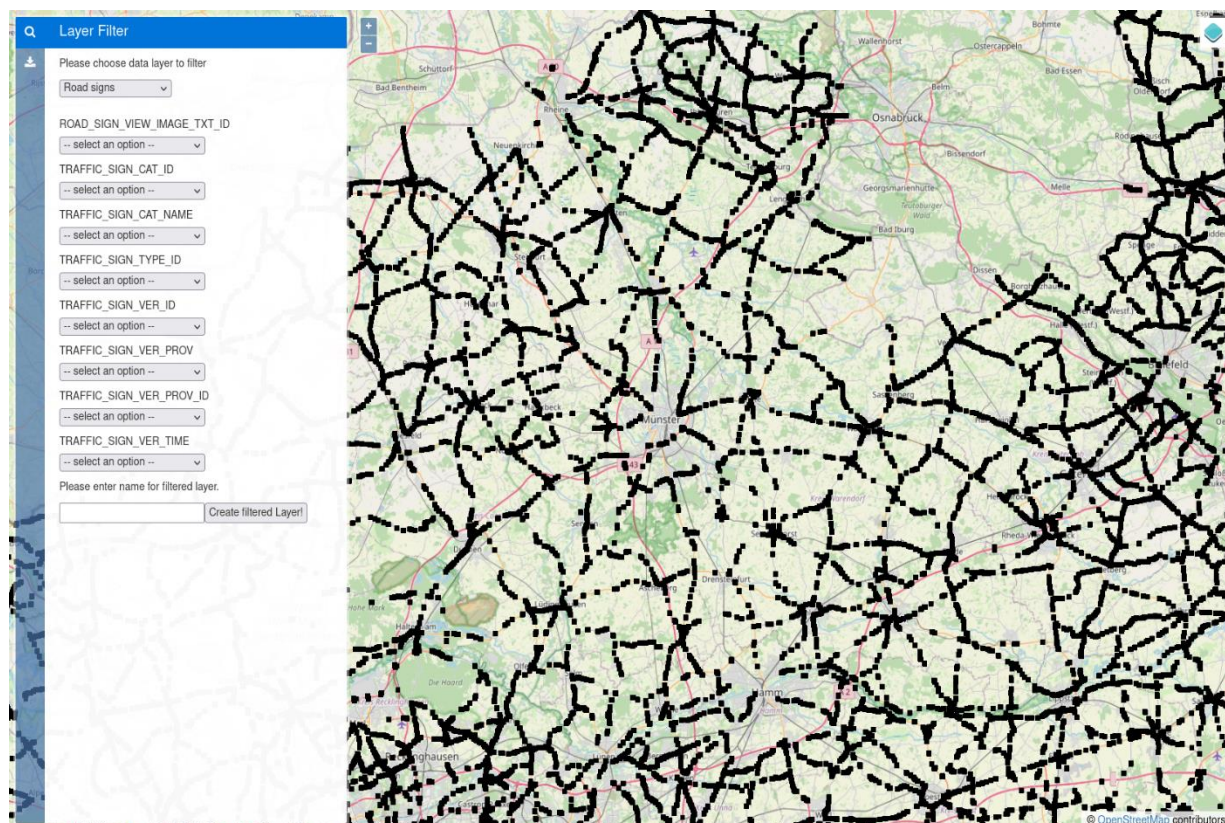


Abbildung 38: Implementierungsprototyp eines Front-End als Web-Applikation

Stattdessen wurde entschieden, die Daten über ein QGIS-Projekt verfügbar zu machen. QGIS stellt bereits sehr umfangreiche Funktionen zur Bearbeitung von Geo-Daten aus Geo-Datenbanken zur Verfügung. Die Erstellung von Stichproben, samt der aufwändigen Verknüpfung mit den Verkehrsströmen und Unfalldaten, gelingt weitgehend mit diesen bereits vorhandenen Funktionen. Allein sehr spezifische Funktionen zur Filterung der Merkmale mit Vorher/Nachher-Vergleich und räumlicher Gruppierung um die Kreuzungspunkte herum wurden in dem QGIS-Plugin „MaKaU Workbench“ realisiert.

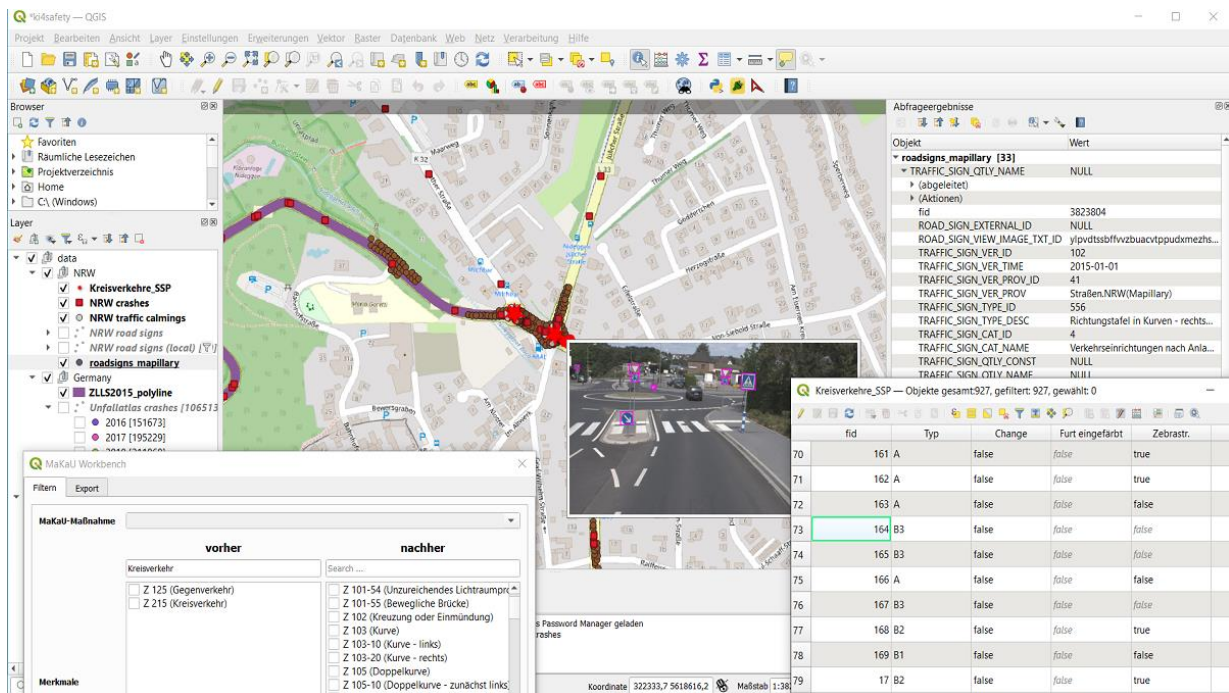


Abbildung 39: Erstellung und Bearbeitung der Geo-Datenbank in QGIS

Dabei wurde als Bedienphilosophie verfolgt, dass dieses Plugin lediglich diejenigen Funktionen anbietet, die tatsächlich nicht über die bereits vorhandenen Möglichkeiten von QGIS realisierbar sind. So wurden Import/Export-Methoden wieder aus dem Lastenheft gestrichen, nachdem klar wurde, dass allein die Verarbeitung von einem bzw. mehreren Eingangslayern zu einem gefilterten Ausgangslayer ausreichend ist, um die Stichprobe zu erzeugen. Ein Review der Stichprobe kann dann wiederum sehr effektiv und effizient über die in QGIS vorhandene Funktion der Attributtabelle erfolgen.

Für den Zugriff auf die Befahrungsdaten wurde die Fähigkeit von QGIS genutzt, externe Web-Inhalte über eine URL abzurufen. Im Fall von KI4Safety zeigt die URL auf einen Web-Service, welcher passend zum Schlüssel aus der Attributtabelle des Datenpunktes das entsprechende Befahrungsbild samt einer Visualisierung der erkannten Merkmale anzeigt. Das Befahrungsbild kann in QGIS direkt

angezeigt werden. Sofern sich diese Ansicht als zu klein erweist, kann man sich durch einen gezielten Klick auf das Bild direkt auf die Ausgabe des Web-Service weiterleiten lassen und das vollständige Bild in seiner vollen Auflösung (im Fall von NWSIB: Full HD) in Augenschein nehmen.

Für Vorher/Nachher Vergleiche kann man über das QGIS-Plugin Send2GE (siehe auch https://github.com/nextgis/send2google_earth) zu einer Geo-Position innerhalb von Google Earth (siehe auch https://de.wikipedia.org/wiki/Google_Earth) springen und dort über historische Luftbilder abgleichen, ob es eine bauliche Veränderung gegeben hat.

Nach kurzer Einarbeitungszeit kann sich der Bearbeiter sehr schnell über Luftbilder, Kartenansichten und Befahrungsbilder in zeitlicher und räumlicher Dimension bewegen und effektiv innerhalb einer geringen Bearbeitungszeit große Stichproben sammeln. Der Workflow ist daher semi-automatisiert. Dies ist aus folgenden Gründen notwendig:

- Deep-Learning Algorithmen machen bei der Merkmalsextraktion Fehler. Diese müssen händisch korrigiert werden, wenn man die Stichprobe zusammenstellt.
- In NWSIB sind die Verkehrsströme von den Zählstellen auf die einzelnen Netzkanten extrapoliert worden. Dies macht es sehr einfach, Geo-Positionen DTV-Werte zuordnen zu können. Allerdings ist die Zuordnung manchmal fehlerhaft, z.B. an Autobahnunterführungen. Solche Orte müssen händisch aus der Stichprobe entfernt werden.
- Für bestimmte Differenzierungen ist es nicht sinnvoll, extra einen Deep-Learning-Algorithmus anzulernen. Stattdessen geht es schneller, wenn man bestimmte Merkmale durch eine virtuelle Begehung feststellt. Später können aufgrund der so gewonnenen Stichproben immer noch Trainingsdaten extrahiert werden um die Stichprobe ggf. zu erweitern.

Ist die Stichprobe definiert, z.B. als Layer in einem Geo-Package, dann können die zugehörigen Unfalldaten und der DTV mit den in QGIS zur Verfügung stehenden Methoden extrahiert werden. Eine mögliche Vorgehensweise ist in Anhang 4 skizziert.

4.2. Erfahrungen bei der Zusammenstellung von Stichproben

Um die Ergebnisse der KI einerseits, sowie die praktische Anwendung des entwickelten Tools (MakauWorkbench) andererseits zu prüfen, wurden verschiedene Stichproben zusammengestellt und ausgewertet. So wurde als Basis für die in Kapitel 4.3 dargestellte Fallstudie mit Hilfe der MakauWorkbench nach Orten mit dem Verkehrszeichen 215 StVO gesucht, um so Kreisverkehre zu identifizieren.

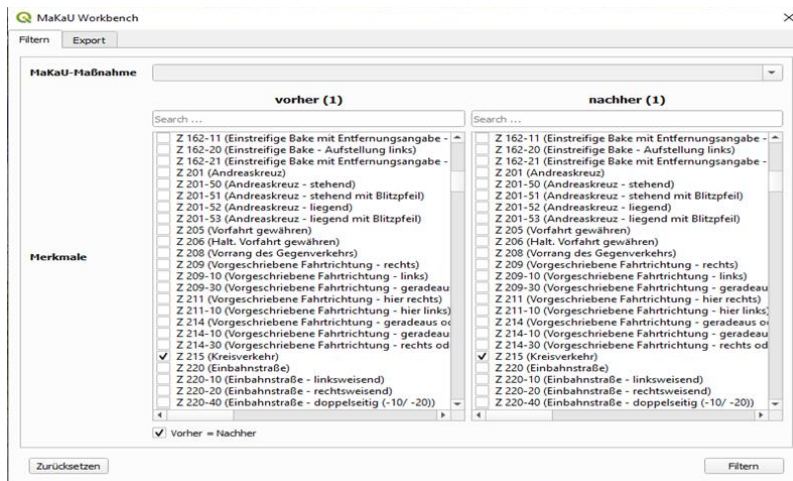


Abbildung 40: Auszug Auswahlmaske

Ergebnis waren auf Basis der zum Zeitpunkt der Auswertung verfügbaren der Daten der KI 19.903 Treffer in der Datenbank. Bei näherer Betrachtung über die zugehörigen Luft- und Befahrungsbilder stellte sich jedoch heraus, dass in vielen Fällen ein und dasselbe Schild in mehreren Befahrungsbildern erkannt wurde.

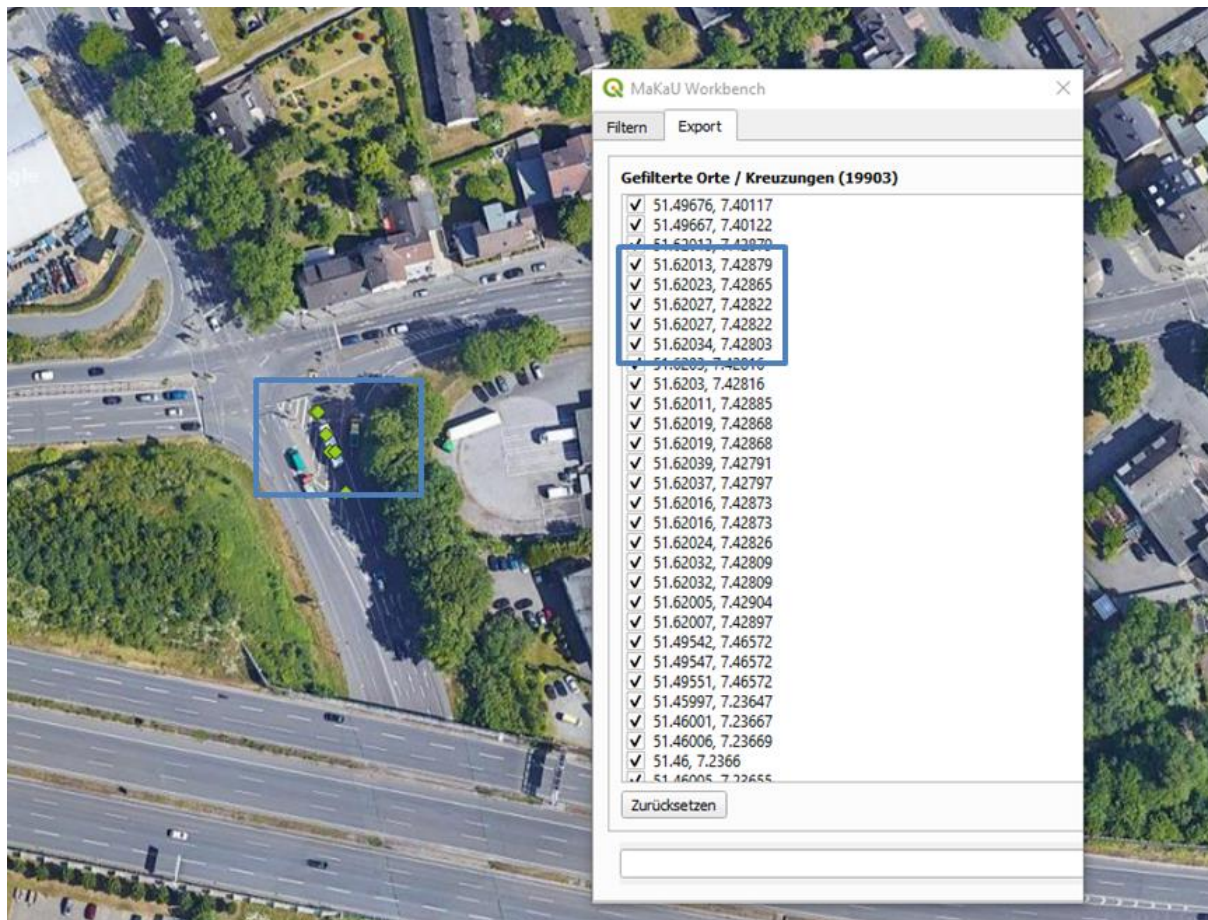


Abbildung 41: Beispiel für die Mehrfacherkennung von Schildern in mehreren Bildern

Eine weitere Auswertung zeigte, dass die Anzahl der real zuzuordnenden Kreisverkehre nur ca. 10% der Detektionsergebnisse der KI für das Verkehrszeichen 215 StVO entspricht. Dies liegt unter anderem auch daran, dass das Verkehrszeichen in der Regel auf allen zuführenden Strecken zu einem Kreisverkehr angeordnet ist. Entsprechende Auswertungen zu anderen Verkehrszeichen haben Zuordnungsraten zwischen 10% und 90% ergeben. Wesentliche Erkenntnisse lassen sich hierdurch daher nicht ableiten.

Für die praktische Arbeit wäre jedoch eine Gruppierung der zusammengehörenden Schilder (welche einen Ort mit der gesuchten Eigenschaft repräsentieren) hilfreich. Daher wurde als Optimierungsvorschlag die Gruppierung von Suchergebnissen innerhalb eines definierten Radius festgehalten und implementiert (siehe Abbildung 42).

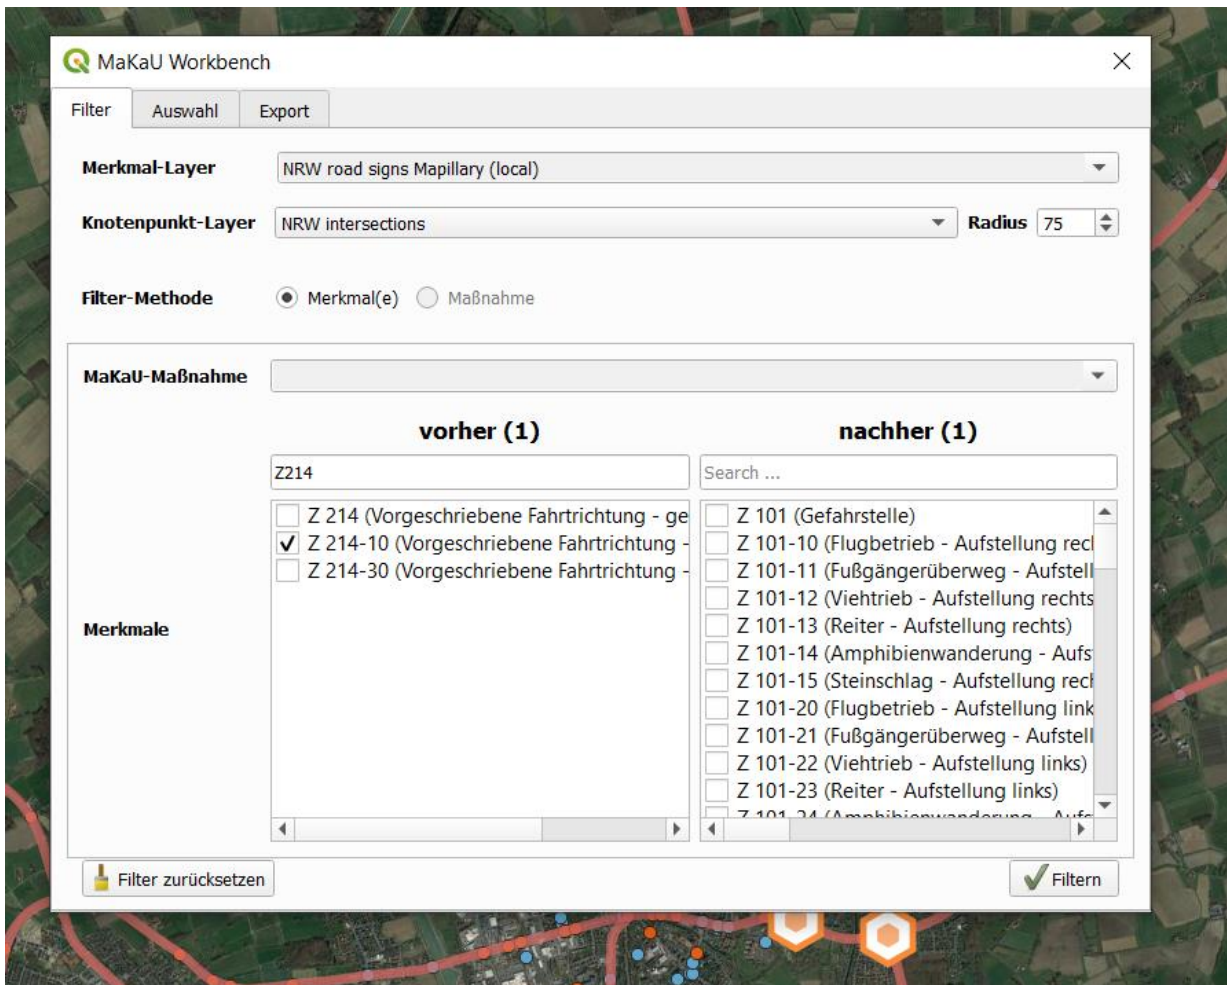


Abbildung 42: Räumliche Gruppierung nach Knotenpunkten in der MaKaU Workbench

Des Weiteren konnte festgestellt werden, dass die Ergebnisse der KI für das betrachtete Verkehrszeichen zu ca. 2/3 richtig (Kreisverkehr) und zu ca. 1/3 falsch (kein Kreisverkehr) waren. Hierzu sei angemerkt, dass die Ergebnisgenauigkeit der KI parallel durch die oben beschriebenen Verfahrensansätze verbessert werden konnten. Genaue Aussagen zur Genauigkeit können der Ergebnisse der KI können daher hier nicht gemacht werden, da die abschließenden Daten die KI nicht mehr rechtzeitig für entsprechende Auswertungen zur Verfügung standen. Es kann aber festgestellt werden, dass je mehr Aufwand in das Anlernen der KI investiert wird, desto besser die Ergebnisse sind (siehe auch Kapitel 3).

Eine 99,9% Genauigkeit ließe sich zwar vermutlich erreichen, der Aufwand hierfür wäre jedoch so hoch, dass der hier vorgesehene Anwendungsbereich dies nicht rechtfertigt. Gleichzeitig zeigte sich jedoch auch, dass selbst mit der vorliegenden Ergebnisgenauigkeit eine Zusammenstellung von Stichproben mittels manueller „Nachbearbeitung“ (siehe hierzu auch Kapitel 4.1) sehr effizient möglich ist.

Dies ist insbesondere daher möglich, da die Einbindung von Befahrungsbildern in Kombination mit der Nutzung von Luftbildern schnell einen guten Eindruck über die örtlichen Verhältnisse (siehe auch Abbildung 42, in der auch die Kennzeichnung der identifizierten Verkehrszeichen zu erkennen ist) vermittelt.

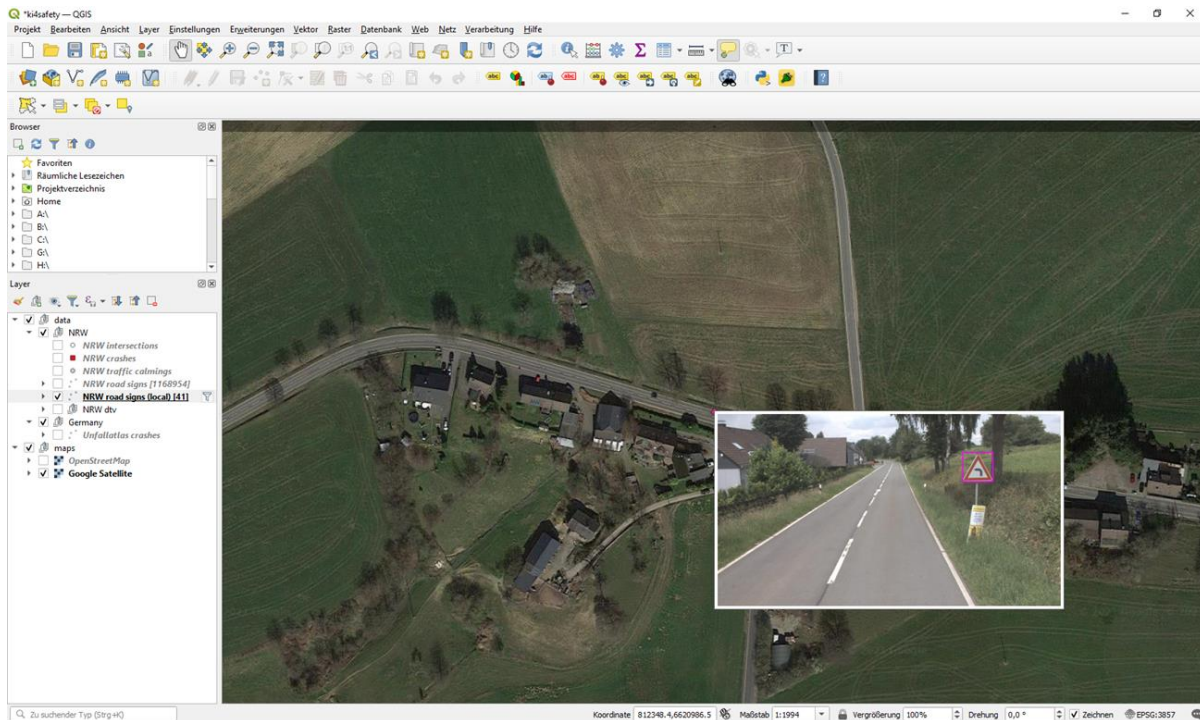


Abbildung 43: Beispiel für die kombinierte Nutzung von Luft- und Befahrungsbildern

Die Darstellung der Suchergebnisse in Kombination mit der Visualisierung ggf. weiterer Daten ermöglicht die Zusammenstellung von verhältnismäßig großen Stichproben ohne größeren Zeitaufwand. Dies gilt trotz der Notwendigkeit einer manuellen Sichtung. Abbildung 43 zeigt das Beispiel einer Darstellung der Lage von Unfällen, Verkehrszeichen (VZ) und der benachbarten Zählstelle zur Verkehrsdatenerfassung.




Abbildung 44: Beispiel für die kombinierte Darstellung verschiedener Suchergebnisse

Insgesamt hat sich gezeigt, dass der Aufwand für das Anlernen einer KI heute noch sehr hoch ist. Dem entsprechend ist je Anwendungsfall zu prüfen, ob der Aufwand für das Anlernen einer KI für den jeweiligen Anwendungsfall sinnvoll ist oder es nicht wirtschaftlicher ist die Aufgabe manuell oder mit anderen „Werkzeugen“ zu bearbeiten.

Im konkreten Fall hat sich gezeigt, dass eine Kombination aus der Anwendung einer KI mit einer „mittleren bis guten“ Genauigkeit der Ausgabeergebnisse und eine manuelle Nachbearbeitung zu einer insgesamt sehr wirtschaftlichen Bearbeitung der zur Demonstration gewählten Aufgabe der „Fallstudie Kreisverkehre“ geführt haben.

Hierzu trägt auch das im Rahmen des Projektes entwickelte Filter- und Visualisierungs-Tool bei. Es hat sich gezeigt, dass sich trotz der oben beschriebenen Probleme eine große Stichprobe zu Kreisverkehren in sehr kurzer Zeit zusammenstellen ließ. Des Weiteren ist durch die manuelle „Nachbearbeitung“ eine weitere Differenzierung der Ergebnisse unter Berücksichtigung zusätzlicher Aspekte möglich.

Des Weiteren ermöglicht die Kennzeichnung der detektierten Verkehrszeichen (siehe Abbildung 44) eine schnelle Analyse der Ergebnisse zur Schilderkennung der KI. So ist eine effiziente Analyse der Ergebnisse möglich. Es kann z.B. schnell festgestellt werden welche Verkehrszeichen zu Fehldetektionen führen (z.B Detektion von Z 215 anstelle von Z 209 – siehe Abbildung 44)



Abbildung 45: Beispiel für die Kennzeichnung detektierter Verkehrszeichen über KI

4.3. Fallstudie Kreisverkehre

4.3.1. Stichprobe

Um die Leistungsfähigkeit des hier beschriebenen Systems zu demonstrieren, wurden die Kreisverkehre in Nordrhein-Westfalen (NRW) untersucht. Auf Basis der KI-gestützten Schildererkenung wurde eine Vorauswahl möglicher Kandidaten getroffen und diese dann manuell nachbereitet. Unter anderem wurden sie, wie in der Arbeit von (Bondzio et al., 2012) bei der manuellen Nachbereitung klassifiziert.

Im Prinzip hätte man auch diesen Prozess mit Hilfe einer KI erledigen können. Allerdings stellt sich hier die Frage der Verhältnismäßigkeit: Das entsprechende Anlernen einer KI für diesen Zweck hätte wohl mehr Zeit gekostet als die eigentliche manuelle Annotation. Wenn es mehr Kreisverkehre gegeben hätte, dann hätte sich das Verhältnis natürlich umgekehrt, und eine KI-basierte Lösung wäre die schnellere und effizientere Lösung gewesen.

Mit Hilfe der MaKaU-Workbench wurden insgesamt 1062 Kreisverkehre wie erwähnt manuell klassifiziert und dann noch die entsprechenden Daten mit jedem einzelnen Kreisverkehr verknüpft. An 141 Kreisverkehren, waren keine Zählzeiten Radverkehr vorhanden. Weitere 61 Kreisverkehre wurden aussortiert, weil aufgrund einer angrenzenden Autobahn bzw. eines Kartenfehlers die Daten als nicht verlässlich eingestuft wurden. Es verblieb eine Stichprobe von 859 Kreisverkehren.

In der finalen Version standen damit für jeden Kreisverkehr folgende Informationen zur Verfügung:

- Koordinaten, Klassifikation (A, B1, B2, B3, NA)
 - Kategorie A: Mischverkehr mit und ohne Radverkehrsanlagen in den Knotenpunktarmen,
 - Kategorie B1: umlaufende Radwege mit bevorrechtigter Radfurt,
 - Kategorie B2: umlaufende Radwege mit gemeinsamer Furt für Fußgänger und Radfahrer und
 - Kategorie B3: umlaufende Radwege mit vorfahrtrechtlicher Unterordnung der Radfahrer an Querungsstellen
- Weitere Beschreibungen:
 - wann wurde der Kreisverkehr baulich verändert
 - gibt es rot markierte Furten für Radfahrende,
 - gibt es Zebrastreifen für Fußgänger:innen,
 - gibt es ein Schild „Achtung Radfahrer“
 - gibt es Hinweise auf Radfahrende, die häufig in der Gegenrichtung unterwegs sind
 - befindet sich der Kreisverkehr innerorts oder außerorts
- DTV-Daten aus der Verkehrszählung 2015
- Unfalldaten für 2019 und 2020 aus dem Unfallatlas der Bundesrepublik Deutschland. Die Stichprobe enthält 1680 Unfälle mit Beteiligung von motorisierten Verkehrsteilnehmern und 521 Unfälle mit Beteiligung von Radfahrenden.

Abbildung 46 gibt einen Überblick über die zahlenmäßige Zusammensetzung der Stichprobe. Kreisverkehre vom Typ B3 waren am häufigsten enthalten. Kategorie B1 war die seltenste Kategorie.




Abbildung 46: Zahl der Kreisverkehre nach den verschiedenen Typen A, B1, B2 und B3




Abbildung 47: Histogramm der Radverkehrsbelastungen in der Stichprobe




Abbildung 48: Vergleich der durchschnittlichen täglichen Radverkehrsbelastung vorliegende Stichprobe (gesamt: blau, innerorts: orange) vs. (Bondzio et al., 2012)

Betrachtet man das Histogramm der Radverkehrsbelastung, in Abbildung 47, fällt auf, dass in der Stichprobe häufig geringe Radverkehrsbelastungen auftraten. Im Vergleich zur Stichprobe von (Bondzio et al., 2012) fallen die Verkehrsstärken zudem um ca. den Faktor 10 geringer aus. Die relativen Unterschiede der Belastungen nach Kreisverkehrstyp stimmen allerdings gut überein (vgl. Abbildung 48). Um auszuschließen, dass der Unterschied bei Radverkehrsbelastung daher rührt, dass die vorliegende Stichprobe sowohl innerörtliche als auch außerörtliche Kreisverkehre umfasst, wurde mittels Open Street Map und QGIS Funktionen das Attribut „innerorts/außerorts“ hinzugefügt. Doch auch wenn man ausschließliche innerörtliche Kreisverkehre betrachtet, fallen B3 Kreisverkehre dadurch auf, dass sie die geringsten Radverkehrsbelastungen aufweisen.




Abbildung 49: Histogramm des DTV über alle Verkehrsteilnehmer in der Stichprobe




Abbildung 50: Vergleich der durchschnittlichen täglichen Gesamtverkehrsstärken in der vorliegenden Stichprobe (links) (blau: gesamt, orange: innerorts) im Vergleich zu (Bondzio et al., 2012) (rechts)

Die Gesamtverkehrsstärken passen besser zu den in (Bondzio et al., 2012) kommunizierten Werten, wobei hier ein Faktor 2 vorzuliegen scheint, wahrscheinlich je nachdem ob der Verkehr in Hin- und Rückrichtung summiert wird oder nicht.

4.3.1. Modellauswahl

Bei der Sichtung der Ergebnisse von (Bondzio et al., 2012), Abbildung 71, war Folgendes aufgefallen: *Kreisverkehre vom Typ A, in denen Radfahrende im Mischverkehr fahren, weisen im Durchschnitt auch eine geringere tägliche Radverkehrsbelastung auf.* Setzt man Unfallrate und Radverkehrsbelastung der Typen A und B1 ins Verhältnis, kann man vermuten, dass die höhere Unfallrate sich infolge der erhöhten Exposition – d.h. aufgrund des höheren Radverkehrs einstellt. Anhand der größeren Stichprobe wurde dies im Rahmen von KI4Safety noch einmal überprüft.

Man darf allgemein annehmen, dass Unfallzahlen Realisierungen eines Zufallsprozesses sind, der einer Poisson-Verteilung genügt. Bei einem Poisson-Prozess entspricht die Erwartungswert der Streuung. Aus der Literatur ist allgemein bekannt, dass bei Unfallzahlen die Streuung meist größer ist, als bei einem reinen Poisson-Prozess, sodass ein Fit mit einer Binomialverteilung zu besseren Ergebnissen führt (Hauer, 2004). Weiterhin wird vermutet, dass Mischmodelle eine noch bessere Anpassungsgüte aufweisen (Shankar et al., 1997). Allgemein schätzt ein solches Modell den Mittelwert der zu erwartenden Unfallzahl durch Auswahl optimaler Parameterwerte β in folgender Formel:

$$\mu = Q^{\beta_{mot}} Q^{\beta_{bike}} e^{\beta_0 + \beta_1 x_1 + \dots + \beta_n x_n},$$

wobei x_i die Einflussgrößen bezeichnen (z.B. ist der Kreisverkehr vom TypA). Sofern die Parameter β_{mot} bzw. β_{bike} nicht den Wert 1 haben, ist es nicht zulässig, aus der Betrachtung jährlicher Unfallraten, ihrer empirischen Erwartungswerte und Streuungen Rückschlüsse auf das Unfallgeschehen zu ziehen.

Es wurde angenommen, dass der Mittelwert der Unfallzahlen sich als ein lineares Modell darstellen lässt:

$$\mu = \beta_0 + \beta_1 \log Q_{car} + \beta_2 \log Q_{bike} + \beta_3 \text{Typ} + \beta_4 \text{FurtGefärbt} + \beta_5 \text{Zebrastr}$$

Die Unfallzahlen selbst folgen einer negativen Binomialverteilung mit diesem Mittelwert und einem weiteren Parameter $\theta \approx 1.6$, der die Abweichung von einer Poissonverteilung beschreibt. Interessant ist an den Ergebnissen, dass die Unfallzahlen von PKW vor allem von Q_{car} (aber nicht von Q_{bike}) abhängen, das umgekehrte gilt für die Unfallzahlen im Fahrradverkehr. Für den PKW ist $\beta_1 = 0.47(7)$, für den Radverkehr ist $\beta_2 = 0.15(5)$, aber jeweils getrennt, d.h. es gibt keinen Term $Q_{car}^{\beta_1} Q_{bike}^{\beta_1}$.

Solche Modelle werden in der wissenschaftlichen Literatur zum Thema Verkehrssicherheit verwendet, von daher ist das Projekt auch in diese Richtung hin anschlussfähig. Um die Bedeutung und Interpretation der Exponenten β_1, β_2 gibt es unserem Kenntnisstand nach noch keinen Konsens.

Um den Einfluss aller sinnvoll erscheinenden Modellparameter, einschließlich der Exposition, bewerten zu können, wurden Modellkandidaten angepasst und folgende statistische Tests auf den Daten durchgeführt:

- Akaike Informationskriterium (AIC) um zu überprüfen, ob das Modell unnötig komplex wird und zur Überanpassung (Overfitting) neigt.

- Prüfung auf Verringerung der statistischen Devianz bei Detaillierung des Modells (Drop-in-Deviance, siehe (Roback, 2021)). Dies ist, zusätzlich zum AIC, ein Test um zu überprüfen, ob das Modell unnötig komplex wird und zur Überanpassung (overfitting) neigt. Dieser Test kann nur spezifisch auf Modelle angewendet werden, für die ein Poisson Fit berechnet wurde. Die Ergebnisse sind dann präziser als der Vuong-Test, weil eine Verteilungsannahme vorausgesetzt wird.
- Prüfung auf Verbesserung der Güte des Modells mittels Vuong-Test. Der Vuong-Test erlaubt es, beliebige Modelle zu vergleichen, naturgemäß ist die Abschätzung aber konservativer.

Folgende Modelle wurden bewertet:

1. Konstante Unfallrate Radfahrer: Jährliche Unfälle mit Radverkehrsbeteiligung bezogen auf den DTV des Radverkehrs. Dies ist vergleichbar mit der Bewertung in (Bondzio et al., 2012)). Da jährliche Unfallzahlen allgemein Realisierungen eines Poisson-verteilten Zufallsprozesses darstellen, wurde ein Fit auf Poisson-Verteilung durchgeführt (Poisson Fit).
2. Konstante Unfallrate für Radfahrer als Funktion der Gesamtverkehrsbelastung
3. Jährliche Unfallzahl als Funktion von DTV und DTV_bike
4. Erweiterung um Unterscheidung zwischen Kreisverkehren mit Bevorrechtigung und ohne Bevorrechtigung ($B_1=B_2$) und ($A=B_3$)
5. Zebrastreifen vorhanden?
 - o Radfahrerfurt rot gefärbt
 - o Radverkehr in Gegenrichtung
 - o Schild „Achtung Radfahrer“ vorhanden
6. Erweiterung auf kombinierte Attribute aus Typ und den anderen Merkmalen. D.h. für Kombination wie TypA mit/ohne Zebrastreifen werden detaillierte Einflussparameter ermittelt.
7. Fit mit Zero Inflated Negativ Binomialverteilung. Das ist ein Mischmodell, welches die Modellierung der Unfallzahlen und zusätzlich ein Modell für Elemente ohne Unfälle beinhaltet (Shankar et al., 1997). Ein solches Modell kann möglicherweise die Unfallsituation noch genauer beschreiben.

Modell	Fit	AIC ↓	Drop-In-De- viance (p-Wert) ↓	Vuong-Test (p-Wert) ↓
1.	Poisson	2004	n.a.	n.a.
2. Q_{bike} vs. 1.	Poisson	1994	<0.01	<0.13
3. $Q_{bike} + Q_{mot}$ vs. 2.	Poisson	1660	<0.01	<0.01
4. β_{type} {AB3;B12} Vs. 3.	Poisson	1546	<0.01	<0.01
5. $+\beta_{zebra}$ vs 4.	Poisson	1526	<0.01	<0.029
6. $+\beta_{ford}$ vs. 5.	Poisson	1499	<0.01	<0.029
7. $+\beta_{type:zebra}$ vs. 6.	Poisson	1498	<0.08	<0.24
8. β_{type} {A; B1; B2; B3} vs. 6.	Poisson	1501*	-	<0,35*
9. β_{type} {AB3; B1; B2} vs. 6.	Poisson	1500	<0.3	<0.34
10. (wie 6. neuer Fit) vs. 6.	NB	1461	-	<0.01
11. (wie 9. neuer Fit) vs. 9.	NB	1462	-	<0.01
12. (wie 7. neuer Fit) vs. 7.	NB	1460	-	<0.01
13. neuer Fit vs 10.	ZiNB	-	-	0.44*

Tabelle 6: Modellauswahl und Ergebnisse der Anpassungstests für Unfälle mit Radverkehrsbeteiligung.

*schlechter als Vergleichsmodell

Anhand von Tabelle 6 ist ersichtlich, dass mehrere Modelle (hellgrün hinterlegt) einen AIC-Wert von ca. 1500 erreichen. Die vergleichenden Tests für die Anpassungsgüte der Modelle zeigen, dass

diese Modelle nicht signifikant voneinander abweichen. Daher kann man feststellen, dass die Unterscheidung zwischen den vier Kategorien A, B1, B2 und B3 detaillierter ist, als notwendig. Eine Unterscheidung zwischen den Kategorien „Radfahrer auf eigenen Radwegen und -Furten bevorrechtigt“ (Typen B1 und B2) und „Radfahrer nicht bevorrechtigt oder im Mischverkehr“ (Typen A und B3) ist entscheidend und ausreichend um das Unfallgeschehen zu beschreiben. Ein solches Modell beschreibt das Unfallgeschehen besser, als alle anderen Modelle, einschließlich der Modelle, die zwischen A, B1, B2 und B3 differenzieren.

Um sicher zu gehen, dass die Modelle funktionieren, wurden die vom Modell geschätzten Unfallzahlen für Teilmengen der Stichprobe, z.B. alle A-Kreisverkehre mit Zebrastr. mit den tatsächlichen Unfallzahlen abgeglichen. Bei diesem Abgleich stellte sich heraus, dass beispielsweise Modell 11 (Tabelle 8) deutlich bessere Ergebnisse abschätzt, als Modell 12 (Tabelle 7), obwohl beide Modelle nach Tabelle 6 ähnliche Ergebnisse beim AIC Wert erzielen. Dies unterstreicht, dass GLM mit hohen Signifikanzniveaus bei allen Einflussparametern besonders leistungsfähig sind.

Modellparameter	Wert	Signifikanzniveau (p-Wert)
$\beta_{0=AB3}$	-5.34	0
β_{B12}	0.78	0
β_{mot}	0.38	<0.01
β_{bike}	0.15	0
β_{zebra}	0.79	0
β_{ford}	0.78	0
$\beta_{B12:zebra}$	-0.47	<0.1
Θ	1.6	

Tabelle 7: Einflussfaktoren Modell 12 für Unfälle mit Radverkehrsbeteiligung

Modellparameter	Wert	Signifikanzniveau (p-Wert)
$\beta_{0=AB3}$	-5.02	0
β_{B1}	0.65	0
β_{B2}	0.46	<0.05
β_{mot}	0.35	<0.01
β_{bike}	0.16	0
β_{zebra}	0.54	0
β_{ford}	0.70	0
θ	1.6	

Tabelle 8: Einflussfaktoren Modell 11 für Unfälle mit Radverkehrsbeteiligung

Eine ähnliche Vorgehensweise wurde bei der Modellauswahl für die Zahl der Unfälle gewählt, an denen motorisierte Verkehrsteilnehmer beteiligt waren. Folgende Modelle wurden bewertet (die Baseline-Modelle 1 und 2 wurden hier weggelassen):

3. Jährliche Unfallzahl als Funktion von DTV und DTV_bike
4. Erweiterung um Unterscheidung zwischen Kreisverkehren mit Bevorrechtigung und ohne Bevorrechtigung (B1=B2) und (A=B3)
5. Wie 4. + Zebrastreifen vorhanden?
6. Wie 5. + Furt rot gefärbt?
7. Statt Unterscheidung zwischen Kreisverkehren mit Bevorrechtigung und ohne Bevorrechtigung Unterscheidung zwischen allen Kategorien A, B1, B2 und B3
8. Wie 6. + Zebrastreifen vorhanden?
9. Wie 5. + Furt rot gefärbt?
10. Wie 7. + Furt rot gefärbt?
11. Gar keine Unterscheidung zwischen den Kreisverkehrstypen A, B1, B2 und B3
12. Wie 10. aber mit Fit auf Negative Binomialverteilung

Modell	Fit	AIC ↓	Drop-In-De- viance (p-Wert) ↓	Vuong-Test (p-Wert) ↓
3. $Q_{bike} + Q_{mot}$	Poisson	2718	-	-
4. $+\beta_{type}$ {AB1; B12} vs. 3.	Poisson	2681	<0.01	<0.01
5. $+\beta_{zebra}$ vs. 4.	Poisson	2639	<0.01	<0.01
6. $+\beta_{ford}$ vs. 5.	Poisson	2627	<0.01	<0.01
7. β_{type} {A; B1; B2; B3} vs. 4.	Poisson	2651	<0.01	<0.04
8. $+\beta_{zebra}$ vs. 6.	Poisson	2635	<0.01	<0.01
9. $+\beta_{ford}$ vs. 5.	Poisson	2630	<0.01	<0.07
10. $+\beta_{ford}$ vs. 7.	Poisson	2627	<0.59*	<0.35*
11. β_{type} {AB123} vs. 10.	Poisson	2625	<0.87*	<0.47*
12. (wie 9. neuer Fit) vs. 9.	NB	2563	-	<0.01

Tabelle 9: Modellauswahl und Ergebnisse der Anpassungstests für Unfälle gesamt. *: Modell ist schlechter als Vergleichsmodell

In Tabelle 9 sind die Ergebnisse zusammengefasst. Es zeigt sich, dass ein Modell, welches den Typ des Kreisverkehrs gar nicht berücksichtigt, den besten AIC Wert erzielt. Allerdings sind die Ergebnisse von Vuong-Test und „Drop-in-Deviance“ zeigen, dass dieses Modell etwas größere Anpassungsfehler aufweist, welche jedoch nicht statistisch signifikant sind. Daher sind diese Modelle als gleichwertig zu betrachten. Nach Datenlage wird es für motorisierte Verkehrsteilnehmer nicht mehr oder weniger gefährlich, ganz gleich ob im Kreisverkehr Radfahrende im Mischverkehr unterwegs

sind, ob sie bevorrechtigt sind oder ob sie den motorisierten Verkehrsteilnehmern Vorfahrt gewähren müssen. Tabelle 10 zeigt, dass die Parameter β_{B1} , β_{B2} und β_{B3} gegenüber der Referenz $\beta_{0=A}$, keine signifikanten Abweichungen zeigen.

Modellparameter	Wert	Signifikanzniveau (p-Wert)
$\beta_{0=A}$	-5.01	0
β_{B1}	0.05	-
β_{B2}	-0.07	-
β_{B3}	-0.01	-
β_{mot}	0.35	0
β_{bike}	0.15	<0.01
β_{zebra}	0.79	0
β_{ford}	0.78	0

Tabelle 10: Einflussparameter und Signifikanzniveau für Unfälle Kfz für Modell 9. in Tabelle 9

Modellparameter	Wert	Signifikanzniveau (p-Wert)
$\beta_{0=AB123}$	-5.16	0
β_{mot}	0.55	0
β_{bike}	0.05	<0.05
β_{zebra}	0.51	0
β_{ford}	0.42	<0.01
θ	3.02	

Tabelle 11: Einflussparameter für Unfälle Kfz für Vorzugsmodell 12. in Tabelle 9

Im Prozess der Modellauswahl ist folgendes deutlich geworden:

- Bei der Modellauswahl sollten neben dem AIC-Wert auch vergleichende statistische Tests (Drop-in-Deviance und/oder Vuong) herangezogen werden, welche Modelle paarweise vergleichen. Die Ergebnisse beginnen sich zu widersprechen, wenn man in der Nähe des Optimums befindet.
- Während der Modellauswahl an sich können Erkenntnisse darüber gewonnen werden, welche Parameter für das Unfallgeschehen wesentlich sind und welche nicht. So zeigt sich, dass:
 - o eine Einteilung in Kreisverkehre mit Bevorrechtigung vs. ohne Bevorrechtigung von Radfahrern auf eigener Infrastruktur für das Unfallgeschehen wesentlich ist. Die Unterscheidung zwischen den Typen A und B3 bzw. B1 und B2 ist nicht wesentlich.
 - o Je nachdem ob Unfälle mit Beteiligung Radfahrender oder Unfälle gesamt betrachtet werden, kann auch die Unterscheidung zwischen den Typen A, B1, B2 und B3 ganz weggelassen werden.
- Der Einfluss der durchschnittlichen täglichen Verkehrsstärken DTV ist differenziert, je nachdem ob man Unfälle mit Radverkehrsbeteiligung betrachtet oder Unfälle gesamt. Der Einflussparameter ist nicht gleich 1. D.h. die Betrachtung von Unfallraten allein kann zu falschen Schlüssen führen.
- Die Unfalldaten haben eine deutliche Überdispersion. Der Fit auf negative Binomialverteilung verbessert die Anpassungsgüte spürbar.
- Der Einsatz von Zero Inflated Negative Binomial Modellen hat keinen messbaren Vorteil.

4.3.2. **Eingehende Betrachtung der Stichprobe**

Abbildung 52 bis Abbildung 55 enthalten Schautafeln, welche die Stichprobe detailliert nach Kreisverkehrstypen und den Merkmalen „Zebrastreifen vorhanden“ und „Furt Rot eingefärbt“ aufstellen. Die Schautafeln enthalten mittlere Verkehrsstärken und Unfallzahlen der jeweiligen Untermengen der Stichprobe und sie zeigen den Wert, welcher anhand der für die Untermenge kennzeichnende Verkehrsstärken und Merkmalskombinationen GLM geschätzt wird. Hier werden Modell 11 (Tabelle 8) für Radverkehrsunfälle und Modell 12 (Tabelle 11) für die Schätzung der Unfallzahlen mit Beteiligung motorisierter Verkehrsteilnehmer verwendet.

	A mit Zebra:		73
DTV_Rad	Unfälle Rad	DTV_mot	Unfälle Kfz
168,19	0,63	8532,81	1,78
Unfallrate Rad	Unfälle Rad GLM	Unfallrate Kfz	Unfälle Kfz GLM
1,50E-02	0,6	1,17E-04	1,94

Abbildung 51: Erläuterung zu den Inhalten der Schautafeln

In Abbildung 51 ist ersichtlich, dass in der Stichprobe von insgesamt 1062 Kreisverkehren 73 Kreisverkehre vom Typ A mit Zebrastreifen enthalten sind. Über diese 73 Kreisverkehre hinweg ergibt sich eine mittlere tägliche Verkehrsstärke von 168 Radfahrenden und 8532 Kraftfahrzeugen. Im Mittel hat es dort in den Jahren 2019 und 2020 laut Unfallatlas durchschnittlich 0,63 Unfälle mit der Beteiligung von Radfahrenden und 1,78 Unfälle mit der Beteiligung von Kraftfahrzeugen gegeben. Das GLM schätzt anhand der DTVs von Radfahrenden und motorisierten Verkehrsteilnehmern, der Tatsache, dass es ein Kreisverkehr vom Typ A vorliegt und dass ein Zebrastreifen vorhanden ist, dass sich auf diesen 73 Kreisverkehren im Mittel ca. 0,60 bzw. 1,94 Unfälle ereignet haben dürften.

Zusätzlich ist eine Aussage zu Unfallraten enthalten. Mittelt man jeweils die Unfallraten für die 73 Kreisverkehre vom Typ A mit Zebrastreifen, so erhält man 1,5 Unfälle/10² Radfahrende DTV und 1,17 Unfälle/10⁴ Kfz DTV innerhalb dieser zwei Jahre.



Abbildung 52: Kreisverkehre Typ A

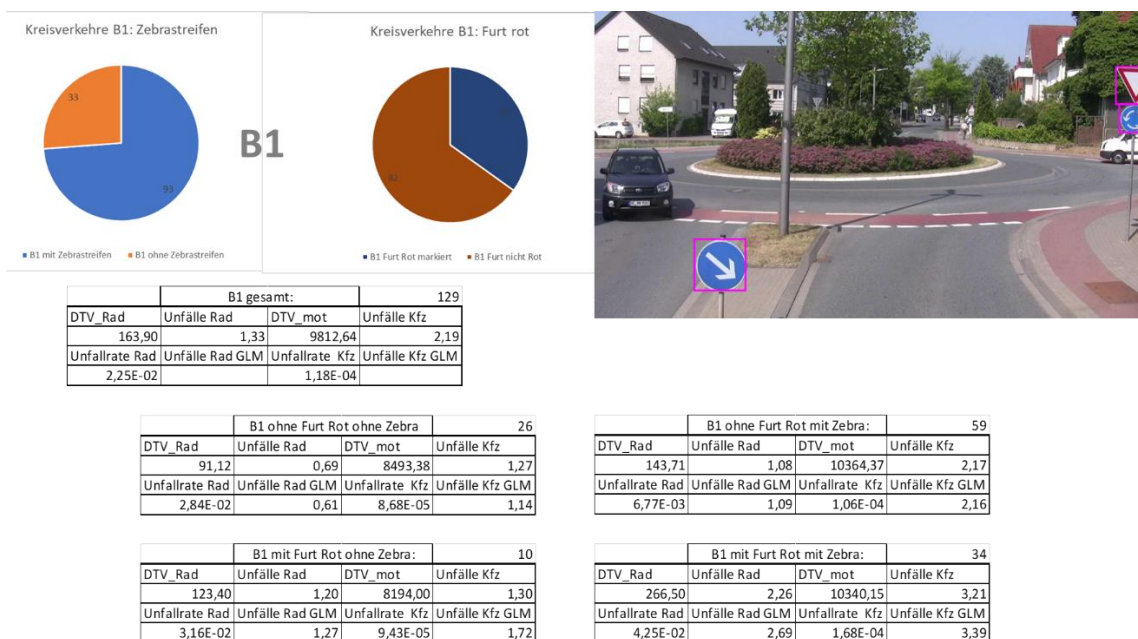


Abbildung 53: Kreisverkehre Typ B1

Anhand von Abbildung 52 und Abbildung 53 lässt sich Folgendes feststellen:

- Bei den Kreisverkehren vom Typ A ist die Radverkehrsbelastung im Schnitt mehr als doppelt so hoch, wenn ein Zebrastreifen vorhanden ist.
- Ähnlich verhält es sich bei Kreisverkehren vom Typ B1: Wenn ein Zebrastreifen vorhanden und eine Furt rot eingefärbt ist, dann sind fast dreimal so viele Radfahrende anzutreffen.
- Typ A-Kreisverkehre mit Zebrastreifen haben eine höhere Radverkehrsbelastung als Typ B1.
- Das arithmetische Mittel der Unfallrate von B1 Kreisverkehren mit Zebrastreifen ist mit einem Wert von $6,8 \cdot 10^{-3} / \text{DTV Radfahrer}$ viel niedriger als für alle Teilmengen ohne Zebrastreifen. In Tabelle 8 ist ersichtlich, dass das Vorhandensein eines Zebrastreifens bei einem Kreisverkehr des Typs B1 zu einer Erhöhung des Unfallrisikos für Radfahrende um ca. 70% führt ($e^{0,55} = 1,73$). Zudem ist ersichtlich, dass das GLM eine sehr präzise Vorhersage der Zahl der Unfälle mit Radfahrendenbeteiligung liefert, nämlich 1,09 vorhergesagte Unfälle vs. 1,08 Unfälle, die sich tatsächlich ereignet haben. Dies zeigt eindrücklich, dass davon abzuraten ist, Mittelwerte von Unfallraten zu erheben, zum Vergleich heranzuziehen und daraus Schlussfolgerungen über die Verkehrssicherheit abzuleiten. Anschaulich kann man sagen, dass es nicht zulässig ist unberücksichtigt zu lassen, ob an einem Ort kein Unfall bei einem DTV von 2000 Radfahrenden aufgetreten ist oder ob das bei 20 Radfahrenden DTV der Fall war.
- Die Hypothese, dass der *Sicherheitsgewinn von Typ A-Kreisverkehren aufgrund der Exposition* zustande kommt, erscheint bei Betrachtung dieser größeren Stichprobe als *unwahr-*

scheinlich. Kreisverkehre vom Typ A (wie auch Typ B3) weisen expositionsbereinigt geringere Unfallzahlen mit Beteiligung von Radfahrenden als B1 bzw. B2 auf, was anhand der großen Stichprobe bestätigt werden kann. Rechnet man Radverkehrsbelastung und den Einfluss des Zebrastreifens heraus, ergibt sich ein Faktor von $e^{0,65} = 1,91$ (Modell 11 gemäß Tabelle 8)



Abbildung 54: Kreisverkehre Typ B2

Ebenso wie bei Typ B1 weisen Kreisverkehre vom Typ B2 mit roter Furt augenfällig eine hohe Verkehrsbelastung auf. Die höchsten Radverkehrsbelastungen wurden auf B1 Kreisverkehren mit roter Furt und Zebrastreifen festgestellt. Solche Kreisverkehre weisen gleichzeitig auch die höchsten DTV aller Fahrzeuge auf.

Kreisverkehre der Kategorien B1 sowie B2 können jeweils eine rote Furt aufweisen. Für Kreisverkehre mit roter Furt können innerhalb der Stichprobe die höchsten Unfallraten festgestellt werden. Dies überrascht, denn (Maier et al., 2016) haben im Rahmen von Vorher/Nachher-Untersuchungen festgestellt, dass die Zahl der Unfälle mit Personenschaden um den Faktor drei abnahm, wenn die Furt rot eingefärbt wurde. Dabei wurde lediglich eine kleine Stichprobe von vier Kreuzungspunkten betrachtet. Die betrachteten Orte waren außerdem vorher Unfallhäufungsstellen und daher von den jeweils zuständigen Unfallkommissionen umgestaltet worden.

Möglich ist, dass sich eine rote Furt an einem Kreisverkehr anders auf die Verkehrssicherheit auswirkt als einem sonstigen Kreuzungspunkt im Straßenverkehr. Sehr wahrscheinlich kommt hier allerdings ein Auswahlereffekt zum Tragen. Furten werden nämlich häufig erst dann rot eingefärbt,

wenn es bereits zu Unfällen gekommen ist (vgl. MaKaU Maßnahme <https://makau.bast.de/massnahmen/133>). D.h. solche Orte haben sich häufig bereits vorher als Unfallhäufungspunkt herausgestellt und tauchen nun in der Stichprobe in größerer Zahl auf, was die Unfallrate innerhalb der Stichprobe nach oben treibt. Plausibel erscheint aber auch, dass Radfahrende auf roten Furten weniger aufmerksam unterwegs sind oder sich im Verkehr selbstbewusster und risikobereiter verhalten. Die rote Furt signalisiert Radfahrer:innen und Kfz-Führer:innen: Radfahrende haben hier Vorfahrt!

Weitere Untersuchungen zur Aufklärung des Phänomens erscheinen notwendig. Neben der Kontaktaufnahme mit den für die 41 gefundenen Kreisverkehre mit roter Furt zuständigen Gemeinden bzw. Unfallkommissionen erscheinen folgende Untersuchungsansätze sinnvoll:

- Verkehrspsychologische Untersuchungen durch Befragung einer repräsentativen Stichprobe von Radfahrenden,
- eine Auswertung der Trajektorien der beteiligten Verkehrsteilnehmer an Kreisverkehren mit und ohne rote Furt sowie
- eine Untersuchung im Simulator.

B3

B3 gesamt:			456
DTV_Rad	Unfälle Rad	DTV_mot	Unfälle Kfz
85,36	0,27	8654,05	1,05
Unfallrate Rad	Unfälle Rad GLM	Unfallrate Kfz	Unfälle Kfz GLM
8,72E-03	0,31	6,70E-05	1,13



Abbildung 55: Kreisverkehre vom Typ B3

Die geringste Radverkehrsbelastung wurde an Kreisverkehren vom Typ B3 festgestellt (vgl. Abbildung 55), bei vergleichsweise hoher Gesamtverkehrsbelastung. Wenn Radfahrer durch das Verkehrszeichen „Z205: Vorfahrt gewähren“ darauf hingewiesen werden, dass sie motorisierten Kraftfahrzeugen Vorfahrt gewähren müssen, dann sind die Unfallraten gering, sowohl wenn man sie auf das Radverkehrsaufkommen bezieht, als auch bezogen auf das Gesamtverkehrsaufkommen. Die Unfallrate ist stets etwas höher als bei TypA-Kreisverkehren, aber geringer als bei allen Varianten von B1 und B2.

4.3.1. Änderungen an Verkehrsführungen (Vorher/Nachher Vergleich)

Im vorangegangenen Abschnitt wurde die Stichprobe vorgestellt und im Sinne eines Ensemble-Vergleichs betrachtet. Besonders klar ist die Aussage einer vergleichenden Studie im Vorher/Nachher-Vergleich. Auswahlfehler können auch hier auftreten, beispielsweise wenn eine Unfallkommission tätig wird aufgrund der Regression zur Mitte (Spahn, 2011). Allerdings kann man im Vorher/Nachher-Vergleich Auswahlfehler im Allgemeinen besser ausschließen.


Es ist jedoch auch besonders schwierig Stichproben für den Vorher/Nachher-Vergleich zusammenzustellen. Entsprechend konnten nur zwei Änderungen an Radverkehrsführungen innerhalb der gesamten Stichprobe von 926 Kreisverkehren identifiziert werden, siehe Abbildung 56 und Abbildung 57.



DTV_Rad: 105
DTV: 10602
Unfälle Rad 2019/20: keine

Abbildung 56: Änderung einer Verkehrsführung vom Typ B3 auf Typ B2 mit rot eingefärbter Furt

Diese Beispiele verdeutlichen, dass bei Verkehrssicherheitsuntersuchungen umsichtig vorgegangen werden muss. Die Hypothese, dass eine Radfahrfurt allein dann rot eingefärbt ist, wenn eine Unfallkommission tätig war ist für das Beispiel von Abbildung 56 sehr wahrscheinlich nichtzutreffend. Denn eine gut informierte Unfallkommission wird sehr wahrscheinlich nicht eine sichere Verkehrsführung durch eine weniger sichere Verkehrsführung ersetzen. Möglicherweise wurde diese Änderung jedoch aufgrund der steigenden Radverkehrsbelastung durchgeführt.



DTV_Rad: 130
DTV_Gesamt: 11893
Unfälle Rad 2019/20: keine

Abbildung 57: Änderung der Verkehrsführung von Typ B3 auf Typ A mit Zebrastreifen

Im Beispiel in Abbildung 57 ist zu vermuten, dass der Wunsch nach eine Bevorrechtigung von Radfahrenden und Fußgänger:innen befriedigt werden sollte. Hier ist eine Verkehrsführung gewählt worden, für die im vorangegangenen Kapitel geringe Unfallraten bei hohen Radverkehrsströmen festgestellt wurden.

Am Beispiel in Abbildung 58 dagegen wäre ein Eingreifen der Unfallkommission plausibel.



DTV_Rad: 682
DTV_Gesamt: 12498
Unfälle Rad 2019/20: 7

Abbildung 58: Änderung der Verkehrsführung von B1 ohne rot eingefärbte Furt zu B1 mit eingefärbter Furt

Während für Änderungen der Radverkehrsführung nur drei Beispiele gefunden werden konnten, war die Suche nach Änderungen in der Verkehrsführung von Einmündung/Kreuzung zu Kreisverkehr ergiebiger. Es konnten allein in den Daten von (Straßen.NRW) 118 solche Orte gefunden wer-

den (vgl. Abbildung 59). Im Vergleich ist die Stichprobe für diese Art der Änderung der Verkehrsführung in (Maier et al., 2016) mit einem Umfang von lediglich vier Stellen, über ganz Deutschland verteilt, sehr klein und die Ergebnisse kaum repräsentativ.

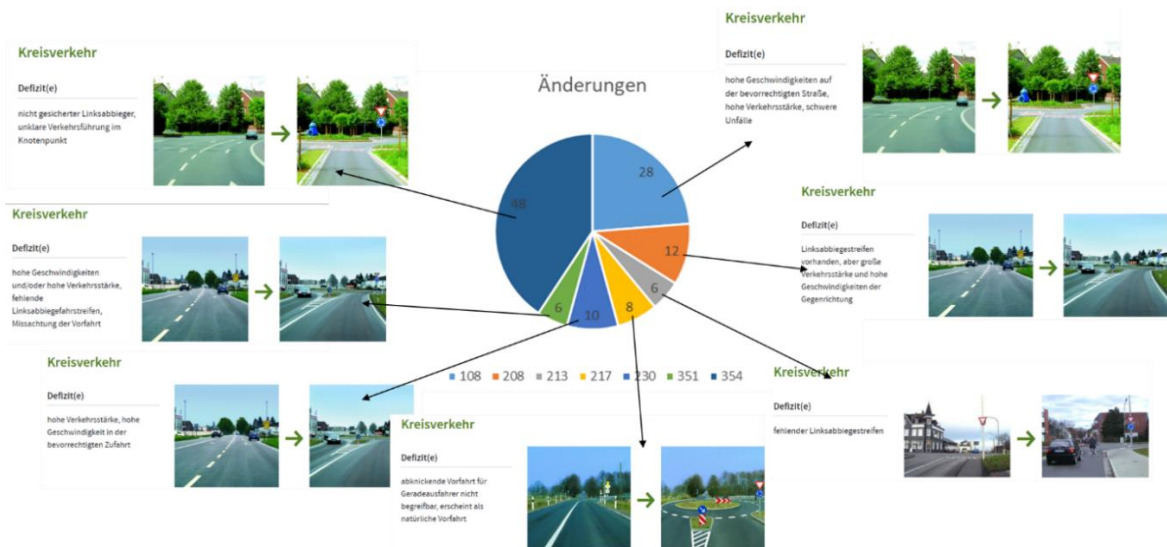


Abbildung 59: Änderungen der Verkehrsführung von Einmündung/Kreuzung zu Kreisverkehr

Dies zeigt eindrucksvoll, dass durch Einsatz von KI auf Big Data viel bessere Voraussetzungen entstehen, um Verkehrssicherheit zu analysieren. Im folgenden Abschnitt wird das anhand einer konkreten Studie zur Verkehrssicherheit an Kreisverkehren gezeigt.

4.3.1. Analyse der Stichprobe

Der Datensatz mit 1062 Kreisverkehren stellt die Grundlage der folgenden Untersuchungen dar, die an die Arbeiten von (Bondzio et al., 2012) angelehnt sind und deren Ergebnisse partiell reproduzieren. Natürlich kann es nicht der Anspruch sein, diese Studie vollständig nachzuvollziehen, es geht hier nur darum, zu demonstrieren wie sich mit relativ geringem Aufwand schon brauchbare Ergebnisse erzielen lassen.

Eines der wichtigsten Ergebnisse von (Bondzio et al., 2012) ist die Beobachtung, dass die vier verschiedenen Kreisverkehrstypen nicht gleichwertig sind, was ihre Sicherheit angeht, siehe Abbildung 60, die direkt dem Bericht entnommen ist. Es wird angemerkt, dass diese Klassifikation in die Typen A, B1, B2 und B3 mitunter schwer zu treffen ist, und dass real existierende Kreisverkehre sich nicht immer uneindeutig in diese Klassifikation einfügen. So wurden im Rahmen von KI4Safety die Ergebnisse mit einem der Co-Autoren von (Bondzio et al., 2012) besprochen und die Zuordnung entsprechend noch einmal angepasst.

Mit dem in diesem Projekt erstellten Datensatz ist es leicht, die Unfallrate für die meisten der 926 Kreisverkehre auszurechnen. Das gelingt allerdings nicht für alle, weil nicht für alle Kreisverkehre

DTV-Werte vorliegen und weil die Daten aus dem Unfallatlas sich nur Unfälle mit Personenschäden enthalten. Unfälle mit Sachschaden werden daher nicht berücksichtigt.




Abbildung 60: Unfallrate für die verschiedenen Kreisverkehrstypen (entspricht Abbildung 72 in (Bondzio et al., 2012)).

Die entsprechenden Analysen zeigen Abbildung 61 und Abbildung 62. Weitere Analysen sind möglich. Aufgefallen ist bei unseren Untersuchungen, dass es eine sehr starke Korrelation zwischen einer rotgefärbten Furt und der Anzahl der Unfälle an einem Kreisverkehr gibt.




Abbildung 61: Unfallrate gesamt in Relation zum Typ des Kreisverkehrs bezogen auf Q_{mot} (DTV).

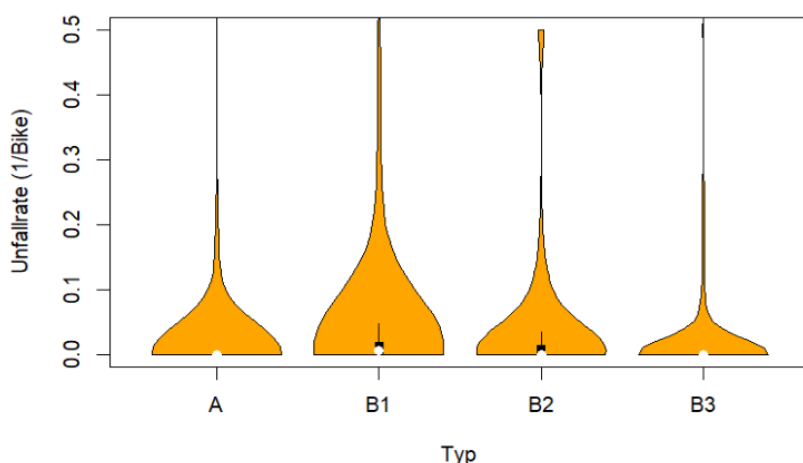


Abbildung 62: Unfallrate für Unfälle mit Radfahrerbeteiligung bezogen auf Q_{bike} (DTV der Radfahrenden)

Anmerkung: Auch hier kommt heraus, dass der Typ B1 der unsicherste ist. Im Unterschied zur Analyse von Bondzio et al. sind die anderen Typen A, B1, B2 aber in Bezug auf die Unfallraten gleich zu bewerten. Die Daten sind als Violinplot dargestellt, um zu demonstrieren, dass hier genügend Daten für diese Art der Auswertung vorliegen.

Das ist in Abbildung 63 dargestellt. Ein entsprechender t-Test ergibt eine sehr hohe Signifikanz ($p=0.02\%$) dass die eingefärbte Furt unsicherer ist. Dies bestätigen auch die geschätzten Parameter der GLM-Modelle, wie in Abbildung 65 für Radfahrer und in Abbildung 67 für die Unfälle der motorisierten Verkehrsteilnehmer ersichtlich ist. Abbildung 66 und Abbildung 64 zeigen einen ähnlichen Effekt für das Vorhandensein eines Zebrastreifens. Das Vorhandensein eines Zebrastreifens dürfte auf höhere Fußgängerzahlen hinweisen, was eine erhöhte Unfallhäufigkeit plausibel erscheinen lässt.




Abbildung 63: Anzahl der Unfälle in Beziehung zu einer eingefärbten Furt.




Abbildung 64: Vorhandensein eines Zebrastreifens und Häufigkeit von Unfällen mit Radverkehrsbeteiligung




Abbildung 65: Vorhandensein einer rot eingefärbten Radfahrerfurt und Häufigkeit von Unfällen mit Radverkehrsbeteiligung




Abbildung 66: Gesamtzahl Unfälle für das Merkmal „Zebrastreifen vorhanden“




Abbildung 67: Gesamtanzahl Unfälle für das Merkmal „Furt rot“

Ein letztes Ergebnis soll eine der Stärken des gewählten Ansatzes von KI4Safety aufzeigen, nämlich KI-Methoden auf Big Data anzuwenden, um große Stichproben zur Verfügung zu haben. Da in

diesem Fall ausreichend Daten zur Verfügung stehen, lässt sich die Unfallbeteiligung weiter disaggregieren. Die Unfalldaten enthalten zu jedem Unfall auch die Verkehrsbeteiligung, sprich die Verkehrsobjekte, die am Unfall beteiligt waren.

Damit lassen sich die Unfallzahlen der verschiedenen Verkehrsbeteiligungsarten ebenfalls dem Typ des Kreisverkehrs zuordnen und ergeben Abbildung 68. Hier ist zu erkennen, dass diese Auswertung an Grenzen stößt. Diese Grenzen lassen sich verschieben, wenn man größere Stichproben zur Verfügung hat.




Abbildung 68: Anzahl der Unfallbeteiligungen für verschiedene Beteiligungsarten in Relation zum Typ des Kreisverkehrs

Die Anzahl der verunglückten Fußgänger:innen zeigt keine signifikante Abhängigkeit von den DTV-Werten und auch keine von den Kreisverkehrstypen. Eine mögliche Erklärung sind die sehr geringen Unfallzahlen für Unfälle mit Fußgänger:innenbeteiligung in diesem Datensatz.




Abbildung 69: Hinweise auf eine Verkehrsführung, bei der Radfahrer:innen zu erwarten sind, welche in Gegenrichtung fahren

4.3.1. Nicht signifikante Einflussparameter

(Bondzio et al., 2012) führen aus: „Bei etwa 38 % aller Unfälle wurde die Querungsstelle im Uhrzeigersinn gequert (Unfalltypen 342 und 343)“. Daher wurde in der Stichprobe vermerkt, wenn Hinweise auf vermehrtes Antreffen von Radfahrern in Gegenrichtung zu erwarten ist. Hier konnte jedoch kein signifikanter Effekt festgestellt werden. Auffällig ist, dass das Auftreten dieses Merkmals mit geringen DTV Radverkehr korreliert ist. Wenn das Merkmal bei Kreisverkehren mit Vorfahrt für Radfahrende auftritt, sind die Unfallzahlen meist geringer.

Falls der Effekt bei Vergrößerung der Stichprobe signifikant wird, ist zu klären, ob das entsprechende Hinweisschild Wirkung hat. (Bondzio et al., 2012) schreiben: „Sofern die Furten entgegen der vorgeschriebenen Fahrtrichtung gequert werden, zeigt sich tendenziell ein defensiveres Fahrverhalten der Radfahrer.“

Weiterhin wurde in der Stichprobe vermerkt, ob das Schild „Achtung Radfahrer“ am Kreisverkehr angebracht ist. Dies wurde bei 19 der 1062 Kreisverkehre festgestellt. Wenn dieses Schild vorhanden ist, sind die Unfallzahlen meist gering, auch bei hohen Verkehrsstärken. Auch dieser Effekt ist nicht signifikant.

Ähnlich verhält es sich mit dem Merkmal „innerorts/außerorts“. Unfallzahlen scheinen innerorts höher zu sein als außerorts. Da bereits 435 Kreisverkehren innerorts und 441 Kreisverkehre außerorts in der Stichprobe enthalten sind, ist nicht zu erwarten, dass der Effekt signifikant wird.




Abbildung 70: Einfluss des Merkmals „beide Richtungen“ auf die Unfallzahlen an Kreisverkehren mit Vorrang für Radfahrer (B1 und B2)

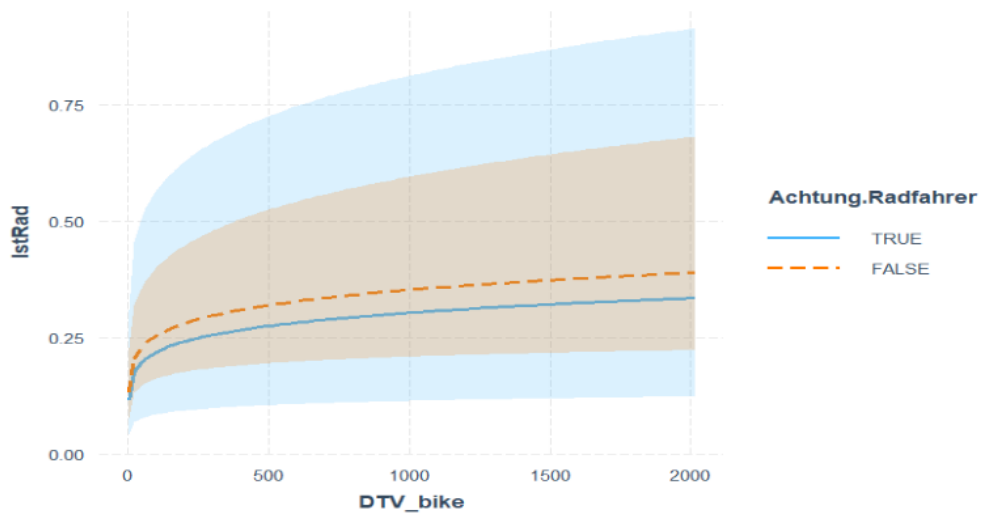


Abbildung 71: Schild „Achtung Radfahrer“

5. Projektdurchführung

5.1. Aktivitäten der Projektpartner

Nachstehend sind die Arbeiten und Erkenntnisse der beiden Partner mit Stand 30.11.2021 kurz zusammengestellt:

Im Vorfeld des Projektstartgespräches wurden zunächst mögliche Untersuchungsansätze und Test-szenarien diskutiert sowie verschiedene Ansätze analysiert (siehe auch weitergehende Ausführungen in den Kapiteln 1 und 2). Darauf aufbauend wurden zur Vorbereitung der Kick-Off-Veranstaltung erste Anwendungs- und Testszenarien skizziert.

Während der Kick-Off-Veranstaltung beim DLR in Berlin im Juni 2019 wurden die Ergebnisse der Voruntersuchung sowie die vorgesehenen Anwendungs- und Testszenarien intensiv und kontrovers diskutiert. Als Ergebnis einigten sich die Projektpartner darauf, dass abweichend von den bisherigen Überlegungen der Maßnahmenkatalog gegen Unfallhäufungen (MaKaU) als Grundlage der Untersuchung fungieren soll (siehe hierzu auch Kapitel 2).

In diesem Kontext wurden im Nachgang die im MaKaU enthaltenen Maßnahmen hinsichtlich einer Möglichkeit zur KI-basierten Detektion aus Luftbildern bzw. Befahrungsbildern analysiert. Hierbei hat sich gezeigt, dass insbesondere 10 Maßnahmen aus dem MaKaU vielversprechend für eine Detektion aus einem Luft- oder Google-Street-View-Bild sind. Nach Abstimmung zwischen den Projektpartnern wurde aus diesen 10 Maßnahmen zunächst eine Maßnahme ausgewählt, die weiter betrachtet wurde.

Hierbei handelt es sich um die MaKaU-Maßnahme 418 (zusätzlicher Beschleunigungstreifen). Für diese Maßnahme wurden im Berliner Stadtgebiet und im Bundesland Brandenburg, für welche das DLR jeweils umfassende Unfalldaten besitzt, passende Knotenpunkte im Luftbild gesucht. Das Ergebnis war jedoch, dass nur einige wenige Knotenpunkte gefunden werden konnten, die zur Charakteristik der Maßnahme passten. Eine weitergehende Betrachtung dieser Maßnahme wurde daher aufgrund des zu geringen Umfangs des verfügbaren Datenmaterials wieder verworfen.

Aus diesem Grund wurden alle MaKaU-Maßnahmen von den Projektpartnern vertieft bewertet, um so geeignete Maßnahmen für eine weitere Betrachtung zu identifizieren (siehe auch Kapitel 2.2). Die Bewertungen wurden in entsprechender Detailarbeit zusammengeführt und katalogisiert (siehe Anlagen 1 und 2).

Aus dieser Auswertung wurden zwei weitere Maßnahmentypen mit folgenden MaKaU-Maßnahmen ausgewählt, die als Testdatensätze für die KI fungieren sollten:

Mittelinsel

- Maßnahme 126
- Maßnahme 223
- Maßnahme 649
- Maßnahme 708

Markierung

- Maßnahme 110
- Maßnahme 798

Knoten, denen diese Maßnahmen zugeordnet werden können, wurden in den Bundesländern Baden-Württemberg, Hessen und Bayern mittels einer Rastersuche per Google-Earth-Satellitenbilder identifiziert und katalogisiert. Kategorien waren dabei:

- eine laufende Nummer zur Identifizierung
- georeferenzierte Koordinaten der identifizierten Maßnahme, um den Knotenpunkt wiederfinden zu können
- MaKaU-Nummer der identifizierten Maßnahme
- Zusatzkennung ob ein Umbau vorhanden war
- Umbauzeitraum (Wenn vorhanden)
- Bemerkungen

Insgesamt wurden hierbei 690 Knoten wie folgt identifiziert:

- | | | |
|--------------------|-----|--------|
| • Maßnahme 126 | 198 | Knoten |
| • Maßnahme 223+649 | 187 | Knoten |
| • Maßnahme 708 | 97 | Knoten |
| • Maßnahme 110 | 42 | Knoten |
| • Maßnahme 798 | 166 | Knoten |

Parallel wurde ein Algorithmus zur automatischen Erkennung von Knotenpunkten in OpenStreet-Map (OSM) entwickelt. An den identifizierten Knotenpunkten wurden dann die jeweiligen Luftbilder in einem nachgelagerten Schritt extrahiert bzw. die Ansichten aus den in Google Street View vorhandenen Befahrungen herausgefiltert. Die Ergebnisse wurden manuell kritisch geprüft und Verbesserungsvorschläge erarbeitet.

5.2. Aktivitäten zur Datenbeschaffung

Parallel zu den oben beschriebenen Aktivitäten der Projektpartner wurden folgende Aktivitäten durchgeführt, um die Datenbasis zu verbessern:

Antrag zur Datennutzung beim Forschungsdatenzentrum Statistik Sachsen-Anhalt (FDZ). Das FDZ führt die Unfalldatenbanken der Länder in einer zentralen Datenbank zusammen. Ein Einblick zur aktuellen Abdeckung kann unter <https://unfallatlas.statistikportal.de/> gewonnen werden. Ergebnisse:

- Nicht alle Bundesländer liefern dem Forschungsdatenzentrum auch Daten. Insbesondere in Nordrhein-Westfalen gibt es große Datenlücken, besonders im Ballungsgebiet zwischen Bonn – Mönchengladbach – Münster – Bielefeld, welches dicht besiedelt ist und eine gute Abdeckung durch Google Street View hat.
- Ein Zugriff auf die ansonsten gute Datenbasis ist für KI4Safety derzeit nicht möglich. Folgender Grund wurde genannt: *„Hintergrund ist, dass für die Herausgabe von Geoinformationen noch kein umfängliches Geheimhaltungskonzept im Rahmen der Statistik der Straßenverkehrsunfälle (STVU) existiert. Ein solches ist die FDZ konstitutiv, um der Forderung der Sicherstellung der Geheimhaltung gerecht werden zu können. Nur die Anwendung gleicher Geheimhaltungskonzepte in FDZ und Fachstatistik verhindert methodische Inkonsistenzen und dadurch Differenzbildungsrisiken.“*
- Der Antrag von KI4Safety wurde zum Anlass genommen um *„auf einen baldigen Abschluss des entsprechenden Konzeptes hinzuwirken. Nach derzeitigem Arbeitsstand ist dies bis Frühjahr/Sommer 2020 fertigzustellen.“* Bis dahin kann jedoch keine Bereitstellung von Geoinformationen der Straßenverkehrsunfälle erfolgen.

Antrag zur Datennutzung beim Landesbetrieb Straßenbau Nordrhein-Westfalen: Aufgrund des Einblicks in den Datenbestand online unter <https://www.nwsib-online.nrw.de/> und nach telefonischer Abstimmung mit den Verantwortlichen wurde festgestellt, dass die Datenbasis von Nordrhein-Westfalen die Lücken in der Datenbasis „Unfallatlas“ gut ausfüllt. Folgende Daten sind für Nordrhein-Westfalen verfügbar:

- hoch aufgelöste Bilder von Streckenbefahrungen unterschiedlicher Jahre
- historische und aktuelle Unfalldaten ab 2005
- historische und aktuelle DTV

Die Daten beziehen sich auf jeweilige Instanzen des Netzknotenstationierungssystems, welches sich über die Jahre ändert. Daher ist eine Umrechnung auf das UTM Koordinatensystem notwendig, da im Projekt UTM die gängige Georeferenz ist.

Antrag zur Datennutzung beim Ministerium des Inneren des Landes NRW für verschiedene Städte in NRW. Dieser Antrag wurde nach schriftlicher Übermittlung und einer telefonischen Rückfrage von Seiten des Ministeriums abgelehnt.

Antrag zur Datennutzung bei den Städten Bremen, Dresden, Köln, Hamburg und Stuttgart. Diese Städte wurden ausgewählt, weil in diesen Städten die Qualität und Dichte der Street-View

Bilder von Google überdurchschnittlich gut sind. Die Städte sind größtenteils sehr aufgeschlossen bezüglich der Übermittlung der Unfalldaten, wenn sie zu Forschungszwecken genutzt werden. Wenn konkrete Daten benötigt werden, ist es möglich Daten von diesen Städten zu erhalten.

5.3. Verbreitung und Bekanntmachung des Projektes

Das Projekt KI4Safety wurde auf folgenden Tagungen vorgestellt:

- Leich, Katzler: Fachmesse "transport logistic", München, 05.06.2019
- Leich: mFund Fachaustausch Künstliche Intelligenz, 02.07.2019
- Leich, Wagner, Kornfeld, Lücken, Hoffmann: Crash Rate Estimation by Aerial Image Analysis, 28.08.2019 – Sino-German Traffic Safety Symposium, BMVI Berlin
- Leich, Tepper, Wagner, Fuchs, Srinivas, Niemeijer: Einsatz von Künstlicher Intelligenz zur Generierung zusätzlicher Verkehrssicherheitsinformationen KI4Safety, 10. Verkehrsmanagementtagung, Berlin, 07.11.2019
- Leich, Trupat, Meuter: Einsatz von Künstlicher Intelligenz in der Verkehrssicherheitsarbeit; KI4Safety. Aachener Straßenbau- und Verkehrstage, Aachen, 22.11.2019
- Wagner: Künstliche Intelligenz für die Verkehrssicherheitsarbeit, mFund-Fachaustausch Verkehrssicherheit, 12.03.2020
- Leich: mFund-Fachaustausch Künstliche Intelligenz, 11.08.2020
- Meuter: KI-Unterstützung gegen Unfallhäufungen, mFund-Fachaustausch Daten und künstliche Intelligenz für eine höhere Straßenverkehrssicherheit, 05.08.2021
- Wagner, Tepper: Aufbau einer Datenbank für sicherheitsrelevante Merkmale der Straßeninfrastruktur zur Verifizierung der Wirksamkeit von Maßnahmen des „Maßnahmenkataloges gegen Unfallhäufungen“, 5. mFUND Konferenz 2021, 19. Und 20.10.2021

Auf diesen Tagungen waren neben Vertretern der assoziierten Partner von KI4Safety weitere Institutionen aus den Bereichen Verkehrsmanagement, Verkehrsplanung und Verkehrssicherheitsarbeit vertreten. Hierdurch kam eine Vernetzung zustande und es wurden auch greifbare Ergebnisse erzielt:

- Es gab einen Kontakt mit Kollegen der HERE Deutschland GmbH. Dabei wurde vereinbart, dass die HERE Deutschland prüft, ob sie dem Projekt KI4Safety Daten bzgl. der Lage von bestimmten Verkehrsschildern auf deutschen Straßen inklusive Historie für Forschungszwecke zur Verfügung zu stellen kann. Später brach der Kontakt wieder ab. Während der Pandemie wurden von HERE keine Anfragen mehr beantwortet.
- Im Austausch mit dem Referenten von BAYSIS (<https://www.baysis.bayern.de/web/>) wurde deutlich, dass die BAYSIS Datenbank auch eine Bewertung der Wirksamkeit der durchgeführten Maßnahmen durch Vorher-Nachher Vergleich leistet, wenn auch basierend auf vergleichsweise kleinen Stichproben.

- Ein Vortrag auf den Aachener Straßenbau- und Verkehrstagen kam auf Einladung des mFUND Projektes FeGiS zustande. Auf der Tagung wurde ein Treffen im Nachgang vereinbart, um weitere Anknüpfungspunkte für die Zusammenarbeit zu identifizieren.

6. Zusammenfassung und Ausblick

6.1. Zusammenfassung

Dieser Bericht enthält einen Abriss der konzeptionellen Arbeiten im Rahmen von KI4Safety in den Jahren 2019 bis 2021. Das Projekt zielt darauf ab, mittels KI-basierten Big-Data Analysen die evidenzbasierte Verkehrssicherheitsarbeit zu stärken. Nach einer ersten sehr intensiven Phase der Datengenerierung und Konkretisierung des Untersuchungsdesigns in 2019 und der ersten Jahreshälfte 2020 haben sich dann für die Hauptbearbeitungsphase in der 2. Jahreshälfte 2020 und in 2021 folgende weitere Meilensteine ergeben:

- Generierung und Konsolidierung der Ergebnisse
- Vorstellung und Diskussion im Rahmen von Betreuerkreissitzungen und Konferenzen mit vergleichbaren Projektinhalten
- Realisierung einer Datenbasis, welche die definierten Untersuchungsfälle umfasst
- Realisierung mehrerer Studien zur Wirksamkeit der ausgewählten Maßnahme bzw. Maßnahmen.

Abschnitt 6.2 beinhaltet Reflexionen zum Einsatz von KI und der Ergebnisse der Untersuchung sowie einen Ausblick auf weitere Optionen zur Konkretisierung und Erweiterung der in KI4Safety entwickelten Toolbox. Ein Ausblick wird in Abschnitt 6.3 gegeben, bevor Abschnitt 6.4 das Fazit enthält.

6.2. Reflexion der Ergebnisse

Um die Fragestellung zu reflektieren, wann bzw. bei welchen Aufgaben der Einsatz einer KI in der Verkehrssicherheitsarbeit generell sinnvoll ist, wird nachfolgend zunächst beispielhaft mit Bezug auf die hier durchgeführten Arbeiten folgende Aufgabe definiert (siehe auch Abbildung 57):

„Suche möglichst viele Knotenpunkte mit drei Ästen für die weitere Datenanalyse“



Abbildung 72: Musterbeispiel für einen Knotenpunkt mit 3 Ästen

Grundsätzlich bestehen mehrere Möglichkeiten die gestellte Aufgabe zu bewältigen. Hier seien beispielhaften drei mögliche Ansätze weiter betrachtet. Zum einen besteht die Möglichkeit die Aufgabe durch manuelle Sichtung der Datenquellen zu erfüllen. Eine weitere Möglichkeit wäre eine automatisierte Auswertung der Datenquellen mittels zu definierender Algorithmen („Programmieren“). Des Weiteren besteht die Möglichkeit eine Künstlichen Intelligenz anzulernen, welche anhand der gelernten Muster die Datenquellen durchsucht.



Abbildung 73: Lösungsmöglichkeiten allgemein betrachtet

Alle skizzierten Lösungsansätze haben ihre Stärken und Schwächen (Vor- und Nachteile).

Eine manuelle Bearbeitung ist z.B. dann sinnvoll, wenn eine kleine, sehr komplexe Datenbasis auszuwerten ist. Würde die Aufgabenstellung lauten „Suche 10 Knotenpunkte mit drei Ästen aus Luftbildern heraus“ ist eine manuelle Auswertung sicherlich die wirtschaftlichste Lösung, da so gut wie kein Vorbereitungsaufwand entsteht und der Umfang der Auswertung sehr gering ist. Sind jedoch mindesten 10.000 Knotenpunkte zu ermitteln so ist dies, wenn überhaupt, nur mit sehr großem zeitlichem Aufwand über eine manuelle Auswertung zu realisieren.

Handelt es sich bei der Auswertung um eine einfache Datenbasis wie z.B. eine Tabelle mit Objekten und deren Attribute kann eine Auswertung für große Datenmengen schnell und effizient über die Definition von Algorithmen (erstellen von Programmen) zur Datenauswertung erfolgen. Bestünde die Datenbasis für die betrachtete Aufgabe aus einer Tabelle mit Knotenpunkten in der als Attribut des Knotenpunktes die Anzahl der Äste angegeben ist, so lässt sich leicht ein Algorithmus zur Auswertung definieren und programmieren, welcher alle Knotenpunkte aus der Liste mit dem gewünschten Attribut extrahiert.

Hierbei ist es kaum von Bedeutung wie viele Knotenpunkte in der Tabelle enthalten sind. Bei einer sehr geringen Anzahl von Knotenpunkten wird jedoch auch hier eine manuelle Auswertung schneller und wirtschaftlicher sein, da für eine Algorithmus-basierte Auswertung als Vorbereitung der Algorithmus zu definieren bzw. ein entsprechendes Programm für die Auswertung zu schreiben ist.

Des Weiteren besteht bei einer komplexeren Datenbasis das Problem der Definition eines passenden Algorithmus – wie sieht z.B. ein entsprechender Algorithmus für eine Detektion von Knoten mit drei Ästen in Luftbildern aus.

Der Einsatz einer künstlichen Intelligenz zur Datenauswertung bedeutet, dass eine künstliche Intelligenz zunächst auf die spezielle Aufgabenstellung trainiert, bzw. angelehrt werden muss. Die Erfahrungen im Rahmen des vorliegenden Projektes haben gezeigt, dass dies heute zum einen noch ein hohes Maß an Fachwissen erfordert und andererseits sehr aufwändig und zeitintensiv ist. So müssen für das Anlernen der KI zunächst Trainings- und Analyse- und Testdatensätze erzeugt werden. Des Weiteren sind die Ergebnisse einer KI mehr oder weniger „zuverlässig“ und bedürfen ggf. einer manuellen Nachbearbeitung. Der Einsatz einer KI ist also vor allem dort sinnvoll wo große und komplexe Datenmengen auszuwerten sind.

Hieran wird Folgendes deutlich:

KI ist keine universelle Lösung für alle Probleme, die bei vergleichenden Untersuchungen in Verkehrssicherheitsanalyse auftreten!

Das vorliegende Projekt hat jedoch gezeigt:

Der Einsatz von künstlicher Intelligenz kann die Bearbeitung bestimmter Aufgabestellungen in der Verkehrssicherheitsforschung deutlich effizienter gestalten, wenn nicht gar erst ermöglichen.

6.3. Ausblick

Die Realisierungschancen für den erfolgreichen Abschluss von weiteren KI-basierten Big-Data-Studien zur Wirksamkeitsanalyse von Maßnahmen nach MaKaU werden derzeit positiv eingeschätzt. Die Sichtung der Ergebnisse zeigt, dass weitere vergleichende Studien zur Sicherheit von bestimmten Verkehrsführungen auf dieser Basis möglich sind und künftig auch erfolgen sollten. Durch die Bereitstellung eines entsprechenden Geo-Packages in der mCLOUD eröffnet sich diese Möglichkeit auch für Dritte.

KI4Safety ist ein Forschungsprojekt, als dessen Ergebnis die Machbarkeit für solche Studien demonstriert und eine Werkzeugkette dazu bereitgestellt wurde. Der Reifegrad der Werkzeugkette muss in der Zukunft allerdings noch weiter verbessert werden. In diesem Zusammenhang sind folgende Maßnahmen zu nennen:

- Verbesserung der Erkennungsleistung, d.h.
 - Reduzierung der Fehler bei der Erkennung von Verkehrszeichen (falsch-positiv Rate, falsch-negativ Rate, falsche Klassifizierung)
 - Fusion von Trainingsdatensätzen, sodass die Liste der erkannten Verkehrszeichen vollständig alle in Deutschland vorkommenden Verkehrszeichen weitgehend abdeckt
 - Generierung von Annotationen neuer Trainingsdaten, sodass alle in Deutschland vorkommenden Verkehrszeichen vollständig abgedeckt werden
- Überführung des adaptiven Lernprozesses in einen toolbasierten Workflow:
 - Für die Erkennung von Mittelinseln wurde gezeigt, dass die Lösung einer komplexen Erkennungsaufgabe mit vergleichsweise geringem manuellem Aufwand zur Generierung von Trainingsdaten gelingt, wenn man die Konfidenz des neuronalen Netzes geeignet bestimmen und bei der Trainingsdatenauswahl berücksichtigen kann.
 - Dieser Ansatz sollte von der reinen Klassifizierung (Mittelinsel enthalten/nicht enthalten) auf weitere Repräsentationen der Artefakte erweitert werden, z.B. Box-Detektionen bzw. pixelgenaue semantische Segmentierungen.
 - Die Werkzeugunterstützung für diesen Ansatz sollte verbessert werden. Es sollte „auf Knopfdruck“ möglich sein, für alle Elemente eines Layers Trainingsbilder zu erstellen, sodass man beispielsweise die Stichprobe der Kreisverkehre nutzen kann, um ein weiteres Netz darauf anzulernen, Kreisverkehre vom Typ A, B1, B2 oder B3 automatisch zu erkennen.
- Integration weiterer Datenquellen
 - Für weitere Bundesländer sind vergleichbare Daten wie in der NWSIB vorhanden. Diese sollten künftig ebenfalls über die mCLOUD zur Verfügung stehen, um noch größere Stichproben, insbesondere für den Vorher/Nachher-Vergleich zu erhalten.
 - Zusätzlich zum DTV können FCD-Daten genutzt werden, um feingranularer zu ermitteln, wie sich der tatsächliche Verkehr zum Unfallzeitpunkt dargestellt hat. Aus

den FCD Daten können Quelle-Ziel-Relationen und Tages- bzw. Wochenganglinien abgeleitet werden.

- o Es ist anzunehmen, dass Daten zur Position von Verkehrsschildern bereits bei der HERE Deutschland GmbH vorliegen. Falls dies der Fall ist und eine entsprechende Vereinbarung getroffen werden kann, ist auch dies wünschenswert.

Der Maßnahmenkatalog gegen Unfallhäufungen (MaKaU) ist bereits bekannt. Der Gedanke, sich beim Einsatz von KI für die Verkehrssicherheitsarbeit am MaKaU zu orientieren, ist im Dialog mit den assoziierten Partnern bei den Projekttreffen von KI4Safety entstanden. Daher ist zu erwarten, dass der Gedanke, vergleichende Untersuchungen künftig mit der Hilfe von KI durchzuführen, auch in der Zukunft aufgegriffen wird. Das direkte Feedback aus der Praxis hat effektiv geholfen, diesen Weg zu finden und zu gehen.

Darüber hinaus ist es auch denkbar, über den Rahmen von MaKaU hinaus mittels KI nach Faktoren zu suchen, welche das Unfallgeschehen beeinflussen. Auch für solche explorativen Untersuchungen hat KI4Safety eine Datengrundlage geschaffen.

6.4. Fazit

Die Verkehrssicherheitsarbeit der Unfallkommissionen beinhaltet im Wesentlichen die Gestaltung von Verkehrsführungen und Verkehrsinfrastruktur mit dem Ziel, die Häufigkeit von Unfällen zu reduzieren. Die Mitglieder einer Unfallkommission können sich dabei bis dato auf den Maßnahmenkatalog gegen Unfallhäufungen (MaKaU) stützen. Aus der Literatur und aus vielen Gesprächen ist dabei bekannt, dass sie sich dabei eher auf ihre Erfahrung verlassen und seltener auf Regelwerke setzen (Maier et al., 2016).

Eine weitere Verbesserung der Evidenz bezüglich der Maßnahmen ist anzustreben. Wenn klar ist, wie gut eine Maßnahme des Maßnahmenkatalogs gegen Unfallhäufungen wirkt, das heißt

- wie viele Unfälle weniger pro Jahr zu erwarten sind
- und wie sicher diese Aussage getroffen werden kann,

dann kann mit konkreten Zahlen argumentiert werden, wenn beispielsweise eine Abwägung zwischen Kapazität und Verkehrssicherheit betroffen werden muss.

Evidenz kann nur auf der Grundlage einer ausreichend großen Datenbasis erlangt werden. Zudem muss sehr sorgfältig gearbeitet werden, um nicht aufgrund von Auswahleffekten zu falschen Schlussfolgerungen zu gelangen. In diesem Zusammenhang sind Fehler durch die Regression zur Mitte sowie durch versteckte Merkmale in der Stichprobe möglich, z.B. weil eine Radfahrerrfurt


häufig erst dann rot eingefärbt wird, wenn bereits eine Unfallhäufung vorhanden ist. Sind genügend Daten vorhanden und wird methodisch sauber gearbeitet, können Fehler ausgeschlossen werden.

Zusätzlich zu den bisher bekannten Methoden zur Zusammenstellung von Stichproben-Daten für vergleichenden Untersuchungen eröffnet der Einsatz von Methoden der Künstlichen Intelligenz neue Möglichkeiten zur Datengewinnung, vor allem im Hinblick auf Massendaten (Big Data), neue Möglichkeiten. Im Rahmen von KI4Safety konnte anhand einer Fallstudie zur Sicherheit von Radfahrenden in Kreisverkehren gezeigt werden, dass bekanntes Wissen bestätigt und zusätzlich differenziertere Einblicke ermöglicht werden können.

Für die Zukunft ist anzustreben, dass das große Potential dieses Ansatzes im Rahmen von Folgeaktivitäten gehoben werden kann, um Verkehrsführungen für alle Verkehrsteilnehmer sicherer zu gestalten.

7. Anhang

Anlage 1: MaKaU-Auswertung



Auswertung:	Bewertung	Maßnahmen	Prozentual
	+	77	28,3%
	0	71	26,1%
	-	124	45,6%
Maßnahmen bewertet:		<u>272</u>	

Anlage 2: Auszug aus MaKaU-Auswertungstabelle

Laufende Nummer	Link	Maßnahme	Ortslage	Konflikte	Defizite	Strecke / Knotenpunkt	Detektierung mit	Bewertung	Anmerkung
1	http://ma-kau.bast.de/masnahmen/502	Leitpfosten aufstellen, Richtungstafeln (Z 625 "Richtungstafel in Kurven")	Außerorts (AO)	1	schlechte Erkennbarkeit des Straßenverlaufs (Straßenkrümmung schlecht einzuschätzen)	Strecke	Street View	-	Leitpfosten auf Luftbild schlecht zu erkennen; In Street View Leitpfostenabstand nur schwer einschätzbar
2	http://ma-kau.bast.de/masnahmen/112	Lichtsignalanlage	Innerorts (IO)	4	mangelnde Erkennbarkeit des Knotens, mangelnde Markierung und Beschilderung, schlechte Sichtbeziehung	Knotenpunkt	StreetView, Luftbild	+	Markierung muss sichtbar sein
3	http://ma-kau.bast.de/masnahmen/138	Lichtsignalanlage	Innerorts (IO)	2	die Wartepflicht ist schlecht erkennbar und erscheint als natürliche Vorfahrt, der Abbiegende (Geradeausfahrt) begreift die Vorfahrtregelung nicht, hoher Belastungsunterschied, mangelnde Markierung	Knotenpunkt	Street View, Luftbild	0	

Anlage 3: Auszug aus Luftbild-Auswertung in Baden-Württemberg

Lfd.-Nr.	Zone	Rechtswert	Hochwert	Mittelinsel / Markierung	Maßnahme	V n vn	Umbauzeitraum		Bemerkung
126	32U	426335.00 m E	5385444.00 m N	Mittelinsel	649	n	-	-	kein Stopsschild
127	32U	426392.00 m E	5385636.00 m N	Mittelinsel	126	v	2009	2014	Haltelinie entfernt
128	32U	416248.00 m E	5383482.00 m N	Mittelinsel	649	vn	2009	2014	kein Stopsschild
129	32U	427596.00 m E	5377741.00 m N	Mittelinsel	649	n	-	-	kein Stopsschild
130	32U	416522.00 m E	5379690.00 m N	Mittelinsel	649	n	-	-	kein Stopsschild

Anlage 4: Beispiel für die Nutzung von bereits in QGIS vorhandenen Funktionen um Stichprobenparameter zu extrahieren

In diesem Beispiel werden durchschnittliche tägliche Verkehrsstärken (DTV) aus NWSIB extrahiert. In der NWSIB Datenbank sind DTV -Werte der Messquerschnitte bereits extrahiert auf die angrenzenden Kanten enthalten. Die Vorgehensweise beinhaltet die folgenden Schritte:

1. Reprojektion des Layer auf UTM-Koordinaten. Dies ist notwendig, weil die folgenden Verknüpfungsoperationen nicht auf Basis von sphärischen Koordinaten durchgeführt werden können.

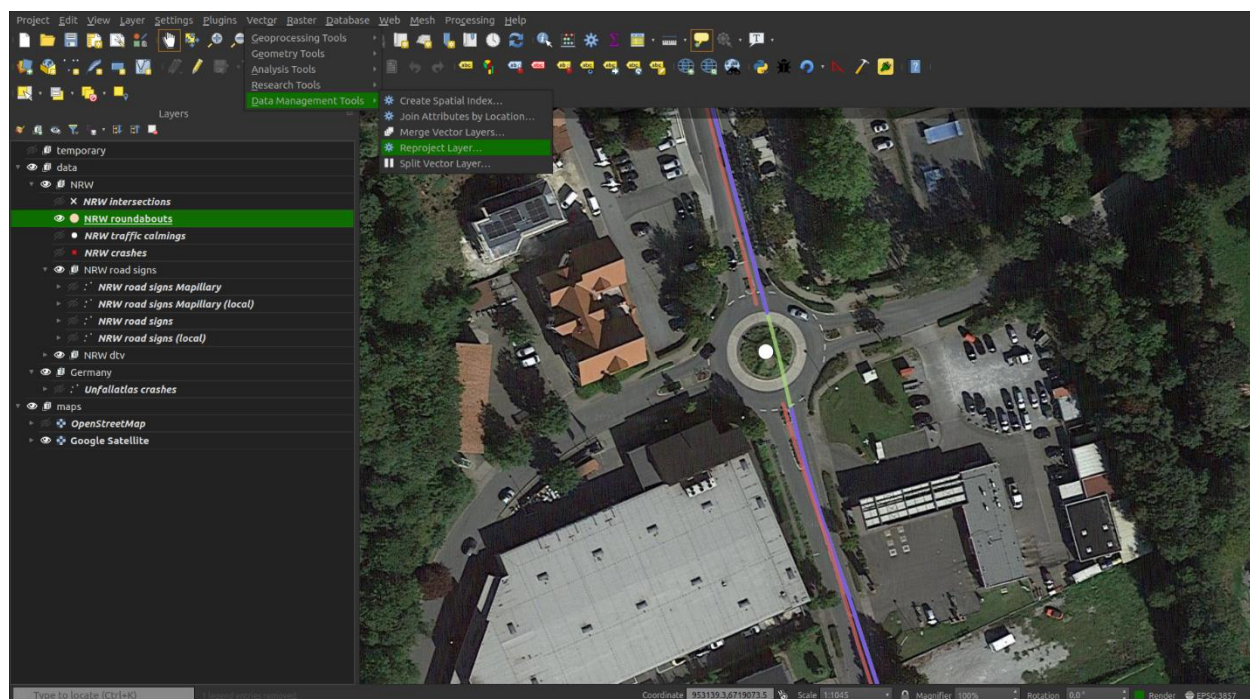


Abbildung 74: Reprojektion (Menü Vektor → Datenmanagement Werkzeuge → Layer Reprojizieren)

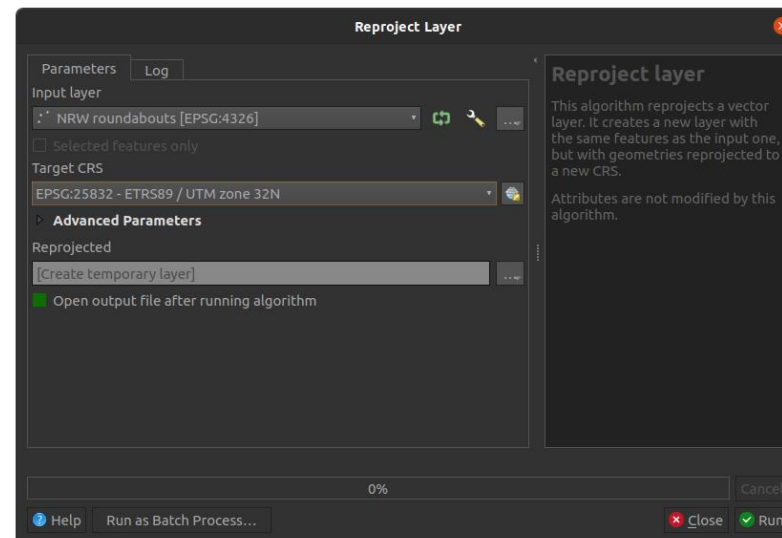


Abbildung 75: QGIS Menü Reprojektion

2. Erstellung eines sogenannten Puffers. D.h. um die Punkte der Stichprobe herum werden kreisförmige Einzugsbereiche angelegt.




Abbildung 76: Puffer (Menü Vektor → Geoverarbeitungswerkzeuge → Puffer)

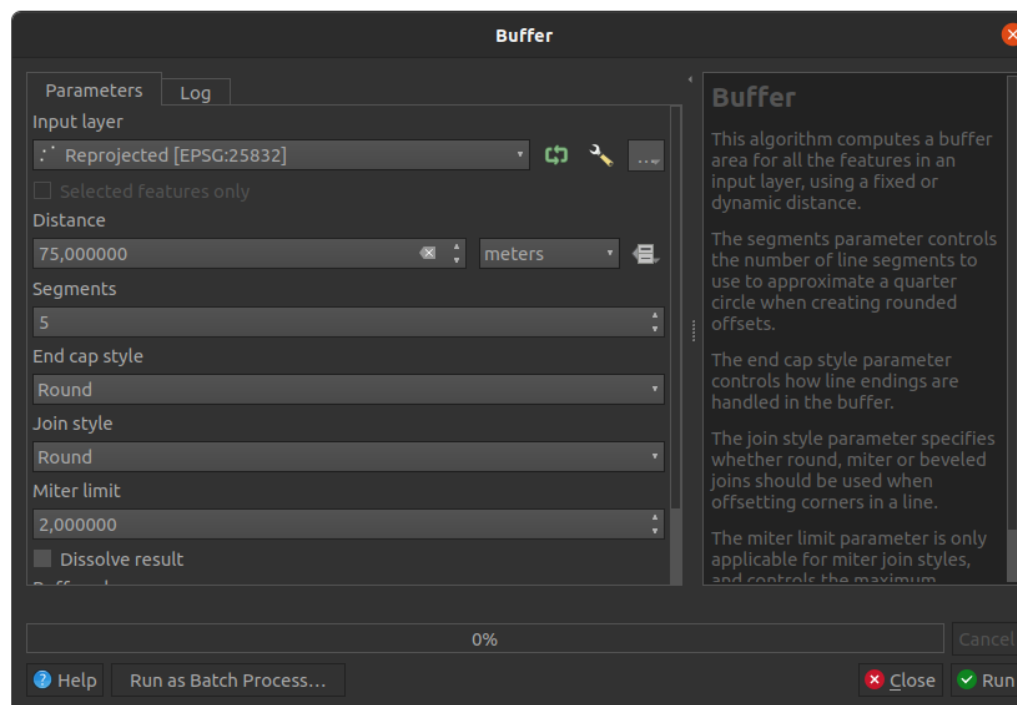


Abbildung 77: Anlage eines Puffers mit 75m Radius

3. Verknüpfung der Stichprobe mit einem Attribut des Layers, welcher die Zählstellennummern des DTV enthält.

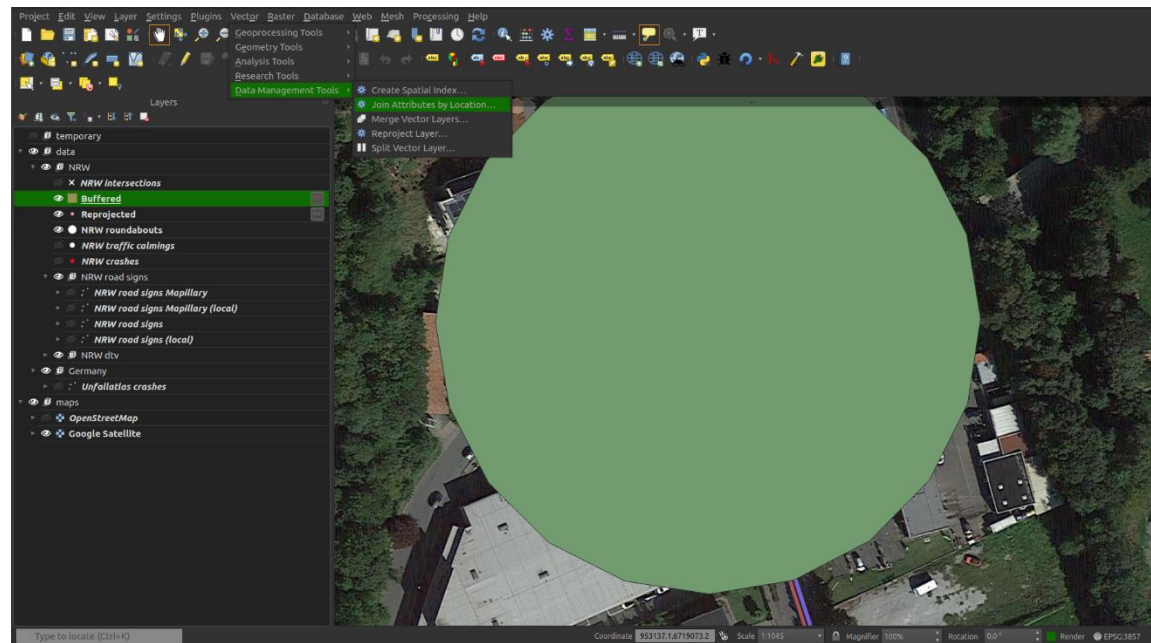


Abbildung 78: Visualisierung der Umgebung mit 75m Radius. Nächster Schritt: Attributverknüpfungsmenü (Menü: Vektor → Geoverarbeitungs-Werkzeuge → Attribute nach Position zusammenfügen)

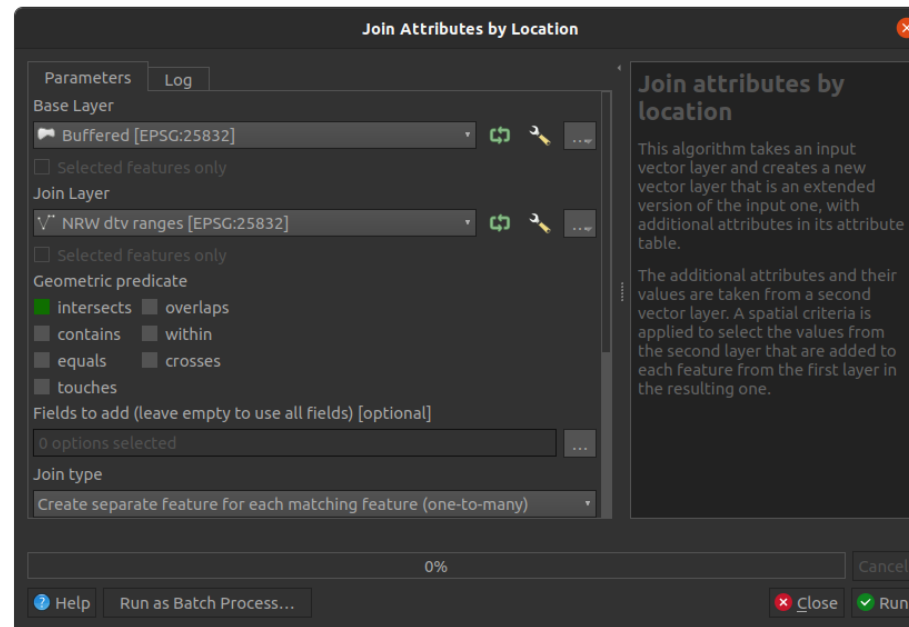


Abbildung 79: Attribute zusammenfügen

													NRW dtv	NRW dtv
													data	data
													2015_SVZ15	2015_SVZ15
fid	fid_2	NR	STRASSE	V05	0	TV15	Vw15	VLV	LV	TVSV	VwSV	DTVRad	DTVKrad	
1	9840	43112202	B 54		8009	9033	6997	7727	6650	7317	347	410	109	95
1	9851	43112220	L 518		12327	8622	9228	9930	8499	9078	728	852	0	104
1	18369	43112202	B 54		8009	9033	6997	7727	6650	7317	347	410	109	95
1	18383	43112220	L 518		12327	8622	9228	9930	8499	9078	728	852	0	104
1	31201	43112202	B54		8009	9033	6997	7727	6650	7317	347	410	109	95
1	31215	43112220	L518		12327	8622	9228	9930	8499	9078	728	852	0	104
1	43200	43112202	B54		8009	9033	6997	7727	6650	7317	347	410	109	95
1	43212	43112220	L518		12327	8622	9228	9930	8499	9078	728	852	0	104
1	9818	43111203	B 54		4337	4667	4915	5201	4662	4896	253	305	64	95
1	18347	43111203	B 54		4337	4667	4915	5201	4662	4896	253	305	64	95
1	31179	43111203	B54		4337	4667	4915	5201	4662	4896	253	305	64	95
1	43189	43111203	B54		4337	4667	4915	5201	4662	4896	253	305	64	95
2	9809	43104315	L 511		7103	6994	7779	8798	7438	8385	341	413	5	146
2	18338	43104315	L 511		7103	6994	7779	8798	7438	8385	341	413	5	146
2	31170	43104315	L511		7103	6994	7779	8798	7438	8385	341	413	5	146
2	43179	43104315	L511		7103	6994	7779	8798	7438	8385	341	413	5	146
2	18329	43102309	L 511		5847	7736	5956	6674	5720	6392	236	281	18	78
2	31160	43102309	L511		5847	7736	5956	6674	5720	6392	236	281	18	78
2	43171	43102309	L511		5847	7736	5956	6674	5720	6392	236	281	18	78

Abbildung 80: Extrahierte DTVs sortiert nach ID innerhalb der Stichprobe. Hier: Kreisverkehre in NRW

8. Literaturverzeichnis

- Azimi, S. M., Henry, C., Sommer, L., Schumann, A. & Vig, E. (2019). SkyScapes - Fine-Grained Semantic Understanding of Aerial Scenes. In *2019 International Conference on Computer Vision: ICCV 2019 : proceedings : 27 October-2 November 2019, Seoul, Korea* (S. 7392–7402). IEEE. <https://doi.org/10.1109/ICCV.2019.00749>
- Bergische Universität Wuppertal. (2014). *Sichere Knotenpunkte für schwächere Verkehrsteilnehmer. Forschungsbericht / Gesamtverband der Deutschen Versicherungswirtschaft e.V.: Nr. 23*. GDV Unfallforschung der Versicherer.
- Bondzio, L., Scheit, M. & Weintert, R. (2012). *Verkehrssicherheit innerörtlicher Kreisverkehre. Forschungsbericht / Gesamtverband der Deutschen Versicherungswirtschaft e.V VI, Verkehrsinfrastruktur: Bd. 5*. Unfallforschung der Versicherer/GDV.
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. In *30th IEEE Conference on Computer Vision and Pattern Recognition: CVPR 2017 : 21-26 July 2016, Honolulu, Hawaii : proceedings* (S. 1800–1807). IEEE. <https://doi.org/10.1109/CVPR.2017.195>
- Deutscher Verkehrssicherheitsrat. (2016). *Verkehrssicherheit an Kreuzungen und Einmündungen erhöhen – Innerorts: Beschluss vom 27. Oktober 2016 auf der Basis einer Empfehlung des Vorstandsausschusses Verkehrstechnik unter Mitwirkung des Vorstandsausschusses Kinder und Jugendliche*. Deutscher Verkehrssicherheitsrat. <https://www.dvr.de/fileadmin/downloads/beschluesse/2016-verkehrssicherheit-an-kreuzungen-und-einmuendungen-erhoehen-innerorts.pdf>
- Ertler, C., Mislej, J., Ollmann, T., Porzi, L., Neuhold, G. & Kuang, Y. (2019, 10. September). *The Mapillary Traffic Sign Dataset for Detection and Classification on a Global Scale*. <http://arxiv.org/pdf/1909.04422v2>
- Forschungsgesellschaft für Straßen- und Verkehrswesen. (2007). *Richtlinien für die Anlage von Stadtstraßen: RASt 06* (2006. Aufl.). FGSV R1 - Regelwerke: Bd. 200. FGSV-Verl.
- Forschungsgesellschaft für Straßen- und Verkehrswesen & Forschungsgesellschaft für Straßen- und Verkehrswesen. (2012). *Richtlinien für die Anlage von Landstraßen: RAL* (FGSV R1 - Regelwerke FGSV 201). Köln.
- Hauer, E. (2004). Statistical Road Safety Modeling. *Transportation Research Record: Journal of the Transportation Research Board*, 1897(1), 81–87. <https://doi.org/10.3141/1897-11>
- Hecht, C. (2017). *Die Verkehrsschau: Rechtliche Rahmenbedingungen, Organisation und Durchführung, Wesentliche Untersuchungspunkte*. https://res.cloudinary.com/adacde/image/upload/v1573033427/ADAC-eV/KOR/Text/PDF/verkehrsschau-adac-bro_jaorgq.pdf
- Houben, S., Stallkamp, J., Salmen, J., Schlipsing, M. & Igel, C. (2013, 4.–9. August). Detection of traffic signs in real-world images: The German traffic sign detection benchmark. In *The 2013 International Joint Conference on Neural Networks (IJCNN)* (S. 1–8). IEEE. <https://doi.org/10.1109/IJCNN.2013.6706807>

- Kingma, D. P. & Ba, J. (2014, 22. Dezember). *Adam: A Method for Stochastic Optimization*.
<http://arxiv.org/pdf/1412.6980v9>
- Lord, D. & Mannering, F [Fred] (2010). The statistical analysis of crash-frequency data: A review and assessment of methodological alternatives. *Transportation Research Part A: Policy and Practice*, 44(5), 291–305. <https://doi.org/10.1016/j.tra.2010.02.001>
- Maier, R., Berger, R., Schmotz, M., Bärwolff, M. & Schimpf, M. (2016). *Kostengünstige Maßnahmen an Unfallhäufungen im Vorher/Nachher-Vergleich: Abschlussbericht Oktober 2016. Forschungsbericht / Gesamtverband der Deutschen Versicherungswirtschaft e.V. Nr. 42.* Gesamtverband der Deutschen Versicherungswirtschaft e.V. Unfallforschung der Versicherer. <https://m.udv.de/de/publikationen/forschungsberichte>
- Pauw, E. de, Daniels, S., Brijs, T., Hermans, E. & Wets, G. (2013). *The Magnitude of the Regression to the Mean Effect in Traffic Crashes*.
- Pschenitza, M. (2017). *Kreuzungsunfälle*. Allgemeiner Deutscher Automobil-Club e.V. Berichte der ADAC Unfallforschung. https://www.adac.de/-/media/pdf/rund-ums-fahrzeug/kreuzungsunfaelle_1886kb.pdf?la=de-de&hash=597349BB0464DC93A2CCD82F4C668448
- R Core Team. (2019). *R: A Language and Environment for Statistical Computing*. <https://www.R-project.org/>
- Ren, S., He, K., Girshick, R. & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Roback, P. (2021). *Beyond Multiple Linear Regression: Applied Generalized Linear Models and Multilevel Models in R*. Chapman and Hall/CRC Texts in Statistical Science Ser. CRC Press LLC. <https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=6456168>
- Sermanet, P. & LeCun, Y. (2011, 31. Juli – 5. August). Traffic sign recognition with multi-scale Convolutional Networks. In *The 2011 International Joint Conference on Neural Networks* (S. 2809–2813). IEEE. <https://doi.org/10.1109/IJCNN.2011.6033589>
- Shankar, V., Milton, J. & Mannering, F [F.] (1997). Modeling accident frequencies as zero-altered probability processes: an empirical inquiry. *Accident Analysis & Prevention*, 29(6), 829–837.
- Spahn, V. (2011). Standardisierte Wirksamkeitsanalyse von sicherheitsverbessernden Maßnahmen an Unfallhäufungen auf Außerortsstraßen. *SCHRIFTENREIHE DES INSTITUTS FUER VERKEHRSWESSEN UND RAUMPLANUNG, UNIVERSITAT DER BUNDESWEHR MUENCHEN*(56). Straßen.NRW. *Straßeninformationsbank Nordrhein-Westfalen (NWSIB)*. <https://www.nwsib-online.nrw.de/>
- Straßenverkehrs-Ordnung vom 6. März 2013 (BGBl. I S. 367)" Neufassung gem. V v. 6.3. 2013 I 367 (2013). *Kraft getreten am, 1*. https://www.gesetze-im-internet.de/stvo_2013/StVO.pdf
- Szegedy, C., Ioffe, S., Vanhoucke, V. & Alemi, A. A. (Hrsg.) (2017). *Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning*.

- Tabernik, D. & Skočaj, D. (2019, 1. April). *Deep Learning for Large-Scale Traffic-Sign Detection and Recognition*. <http://arxiv.org/pdf/1904.00649v1>
- Tcheumadjeu, T., Calvin, L., Ruppe, S., Brockfeld, E. & Yahyaoui, Y. (2010). Traffic Data Platform based on the Service Oriented Architecture (SOA). In *12th World Conference on Transport Research (WCTR)*.
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A. & Torralba, A. (2016, 27.–30. Juni). Learning Deep Features for Discriminative Localization. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (S. 2921–2929). IEEE. <https://doi.org/10.1109/CVPR.2016.319>
- Zhu, Z., Liang, D., Zhang, S., Huang, X., Li, B. & Hu, S. (2016, 27.–30. Juni). Traffic-Sign Detection and Classification in the Wild. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (S. 2110–2118). IEEE. <https://doi.org/10.1109/CVPR.2016.232>