

Abschlussbericht nach 7.3 ANBest-P-Kosten

Zuwendungsempfänger:	Förderkennzeichen:
Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e. V.	19F2008A
Ausführende Stelle:	
Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI, Dresden	

Vorhabenbezeichnung:
Gefahrenstelle_RAD

Laufzeit des Vorhabens:
01.02.2017 bis 31.12.2018

Berichtszeitraum:
01.02.2017 bis 31.12.2018

Inhaltsverzeichnis

1	Wichtigste wissenschaftlich-technische Ergebnisse und andere Ereignisse.....	2
1.1	AP 1: Aufbereitung und Analyse flächendeckender Unfalldaten.....	2
1.2	AP 2: Verfahren zur Erkennung von kritischen Fahrmanövern.....	7
1.2.1	Datenerhebung.....	7
1.2.2	Evaluierung der Sensortechnik.....	8
1.2.3	Mustererkennung.....	11
1.3	AP 3: Fusionierung der Datenquellen und Aggregieren zu Gefahrenstellen	16
1.3.1	Fusionierungskonzept	16
1.3.2	Clustering	18
1.3.3	Bereitstellung	20
1.4	AP 4: Prototypische Umsetzung und Demonstration	21
2	Vergleich Stand des Vorhabens mit Arbeits-, Zeit- und Finanzierungsplanung.....	24
3	Änderungen in der Zielsetzung	24
4	Ergebnisse Dritter mit Relevanz für das Vorhaben	24
5	Öffentlichkeitswirksame Maßnahmen und Austausch mit anderen Initiativen	24
6	Fortschreibung des Verwertungsplans.....	25
6.1	Erfindungen, Schutzrechtsanmeldungen und erteilte Schutzrechte	25
6.2	Wirtschaftliche Erfolgsaussichten nach Projektende.....	25
6.3	Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende.....	26
6.4	Wissenschaftliche und wirtschaftliche Anschlussfähigkeit für eine mögliche notwendige nächste Phase bzw. die nächsten innovatorischen Schritte zur erfolgreichen Umsetzung der FE-Ergebnisse	26

1 Wichtigste wissenschaftlich-technische Ergebnisse und andere Ereignisse

Im Projekt wurden Gefahrenstellen im Radverkehr identifiziert, indem Unfalldatenbanken und kritische Situationen basierend auf Sensordaten ausgewertet wurden. Dazu wurde ein Verfahren zur Ermittlung von Gefahrenstellen für Radfahrer im Verkehrswegenetz entwickelt.

Im AP 1 wurden zunächst Unfalldaten aufbereitet und analysiert. Das Fraunhofer IVI hatte dafür die Möglichkeit, für mehrere Bundesländer monatsaktuelle Unfalldaten der EUSka-Datenbank (Elektronische Unfallsteckkarte) aktuell sowie rückwirkend auszuwerten. Über bereits vom Fraunhofer IVI entwickelte Verfahren ist dies standortbezogen und bzgl. des Unfalltyps sehr differenziert möglich.

Im AP 2 wurde ein Verfahren zur Erkennung von kritischen Fahrmanövern entwickelt. Durch geeignete Sensorik am Fahrrad und der Entwicklung eines Klassifikationsmodells nach Indikatoren wie kommen z.B. Gefahrenbremsungen und abrupte Ausweichmanöver, konnte. Dadurch ist es möglich, neben polizeilich erfassten Unfällen, auch nicht gemeldete Fahrradunfälle bzw. beinahe Unfälle, insbesondere Alleinunfälle mit oder ohne Personenschaden zu erfassen.

Das AP 3 hat sich mit der Fusionierung der Datenquellen und Aggregation zu Gefahrenstellen beschäftigt. Eine räumliche Zusammenfassung verschiedener Unfälle bzw. kritischer Situationen (Clustern) sowie eine Anreicherung durch kontextuelle Umfeld-Daten, insbesondere aus der mCLOUD, wurden in diesem Arbeitspaket durchgeführt.

Im AP 4 wurde eine prototypische Smartphone-Anwendung entwickelt, welche sowohl zur Datenerfassung als auch zur Demonstration der Ergebnisse verwendet werden konnte. Die geclusterten Ergebnisse wurden auf einem FTP-Server im GeoJson-Format zur Verfügung gestellt, um eine Integration in OpenStreetMap und andere Kartentechnologien zu ermöglichen. Sie stehen damit den Radfahrern unmittelbar zur Verfügung, aber z.B. auch für die Nutzung in der mCLOUD, für Planer von Verkehrsanlagen oder Touristiker zur Unterstützung bei der Konzeption von Radrouten. Die Erkenntnisse des Projekts werden in strukturierter Form zusammengefasst und ergänzend zum Datensatz veröffentlicht.

1.1 AP 1: Aufbereitung und Analyse flächendeckender Unfalldaten

In AP 1 wurden Unfalldatenbanken einzelner Bundesländer, die dem Fraunhofer IVI von Polizei- und Landesbehörden übermittelt werden, erstmals nach Unfällen mit Fahrradbeteiligung gefiltert und ausgewertet.

Für die Datenbank „Sachsen“ ergab sich beispielhaft folgendes Gesamtbild über einen Zeitraum von 6 Jahren: Von 779.843 Unfällen waren 34.622 Unfälle mit Radfahrereteiligung:

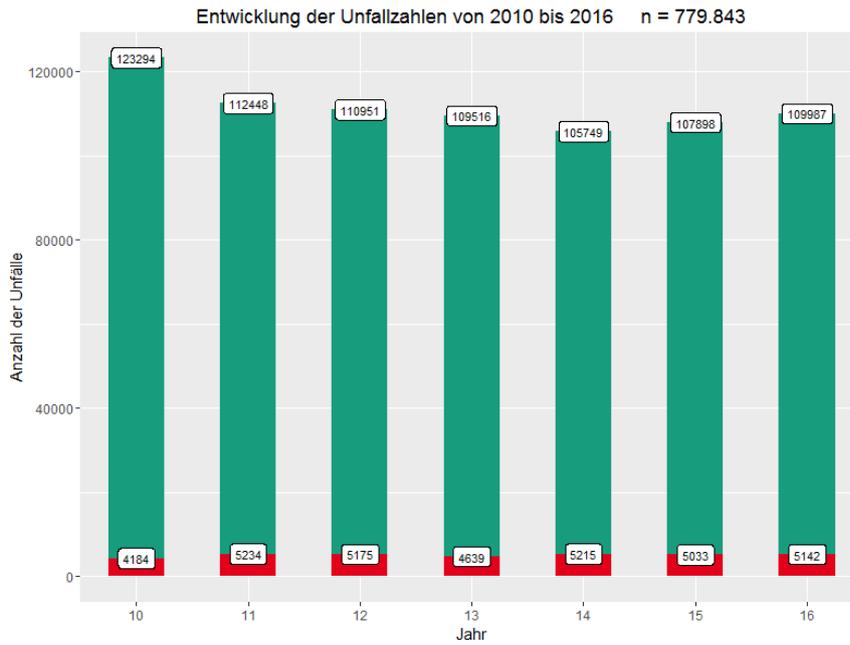


Abbildung 1: Unfallzahlen in Sachsen 2010-2016: Unfälle ohne (grün) und mit (rot) Radfahrerbeteiligung

Dabei weisen Unfälle mit Radfahrerbeteiligung jedoch einen deutlich höheren Anteil an **Personenschäden** auf, da Radfahrer weniger geschützt sind und somit ein deutliches größeres Verletzungsrisiko besteht:

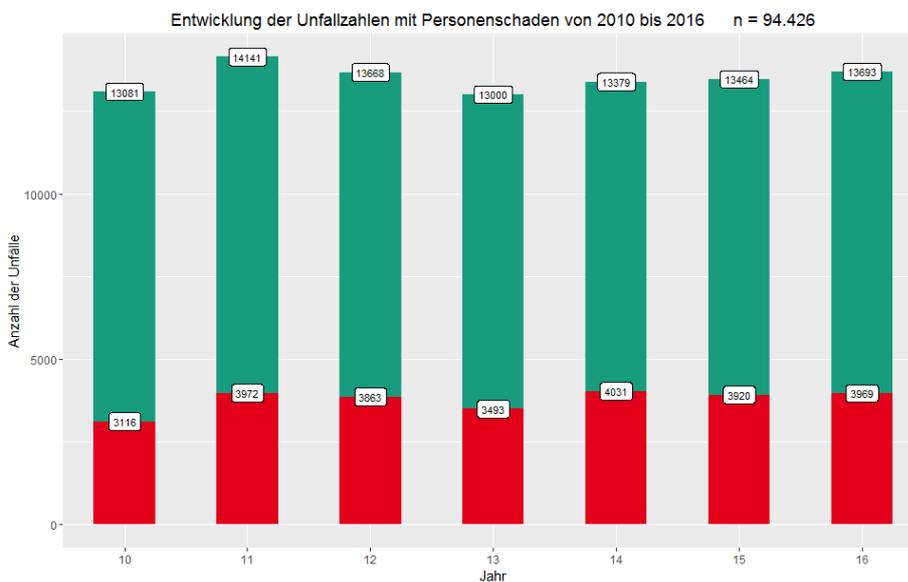


Abbildung 2: Unfallzahlen in Sachsen 2010-2016: Unfälle mit Personenschäden; ohne (grün) und mit (rot) Radfahrerbeteiligung

Beim Verursachen von Unfällen mit Radfahrerbeteiligung wird ersichtlich, dass der Radfahrer selbst in ca. 50% der Fälle der Unfallverursacher war:

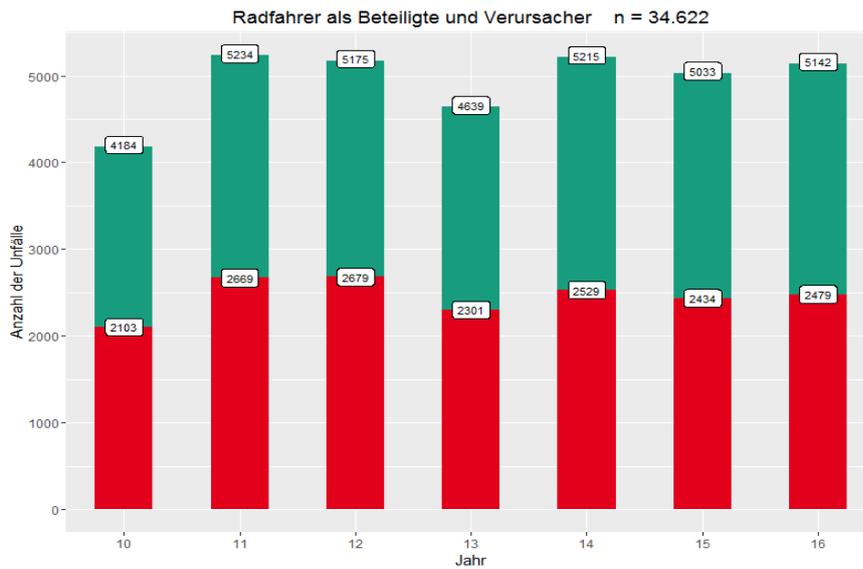


Abbildung 3: Unfälle in Sachsen 2010-2016: Radfahrer als Unfallbeteiligter (grün) und als Unfallverursacher (rot)

Die Unfälle mit Radfahrereteiligung wurden im Anschluss analysiert und auf Einzelunfalltypen (Unfallursache) abgebildet. Dabei zeigt sich, dass Radunfälle am häufigsten beim Einbiegen/Kreuzen und beim Abbiegen passieren:

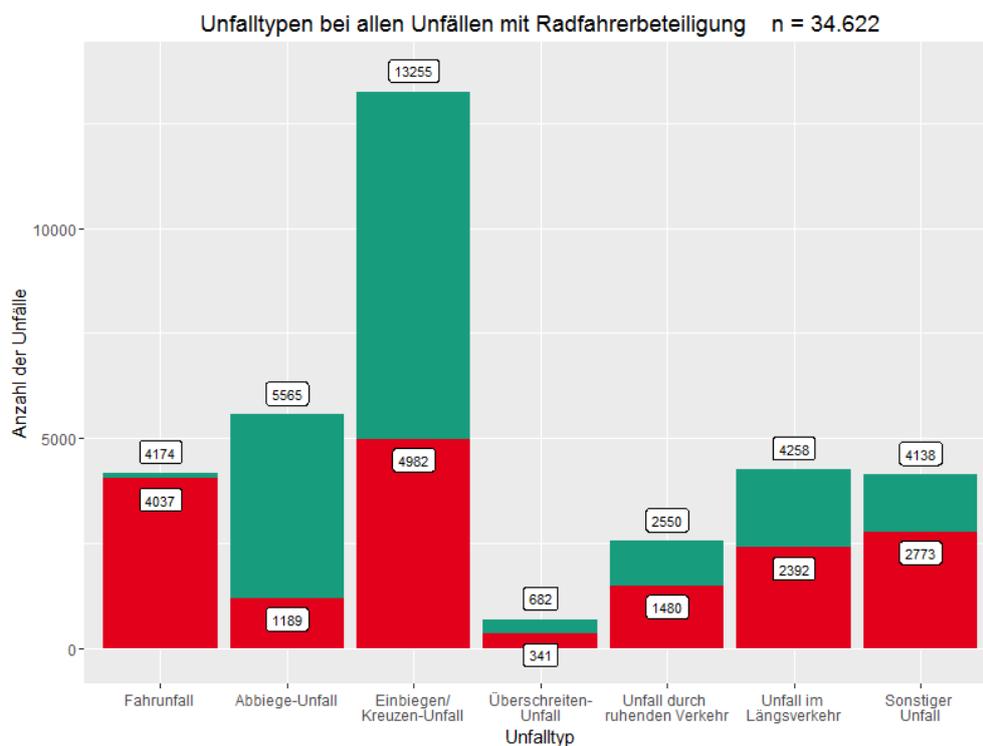


Abbildung 4: Unfälle in Sachsen 2010-2016: Unfalltypen; Radfahrer als Unfallbeteiligter (grün) und als Unfallverursacher (rot)

Die Unfalldaten wurden anschließend nach der Unfallart hin untersucht, die den Unfallablauf **nach** der Entstehungsphase beschreibt. Bei den Unfällen wird unterschieden nach Kollisionen mit bestimmten

Kollisionspartnern (Unfallarten 1 bis 7), Abkommen von der Fahrbahn (Unfallarten 8 und 9) und andere Unfallart (10):

- Unfallart 1: Zusammenstoß mit anderem Fahrzeug, das anfährt, anhält oder im ruhenden Verkehr steht
- Unfallart 2: Zusammenstoß mit anderem Fahrzeug, das vorausfährt oder wartet
- Unfallart 3: Zusammenstoß mit anderem Fahrzeug, das seitlich in gleicher Richtung fährt
- Unfallart 4: Zusammenstoß mit anderem Fahrzeug, das entgegenkommt
- Unfallart 5: Zusammenstoß mit anderem Fahrzeug, das abbiegt, einbiegt oder kreuzt
- Unfallart 6: Zusammenstoß zwischen Fahrzeug und Fußgänger
- Unfallart 7: Aufprall auf ein Hindernis auf der Fahrbahn
- Unfallart 8/9: Abkommen von der Fahrbahn nach rechts/links
- Unfallart 10: Unfall anderer Art

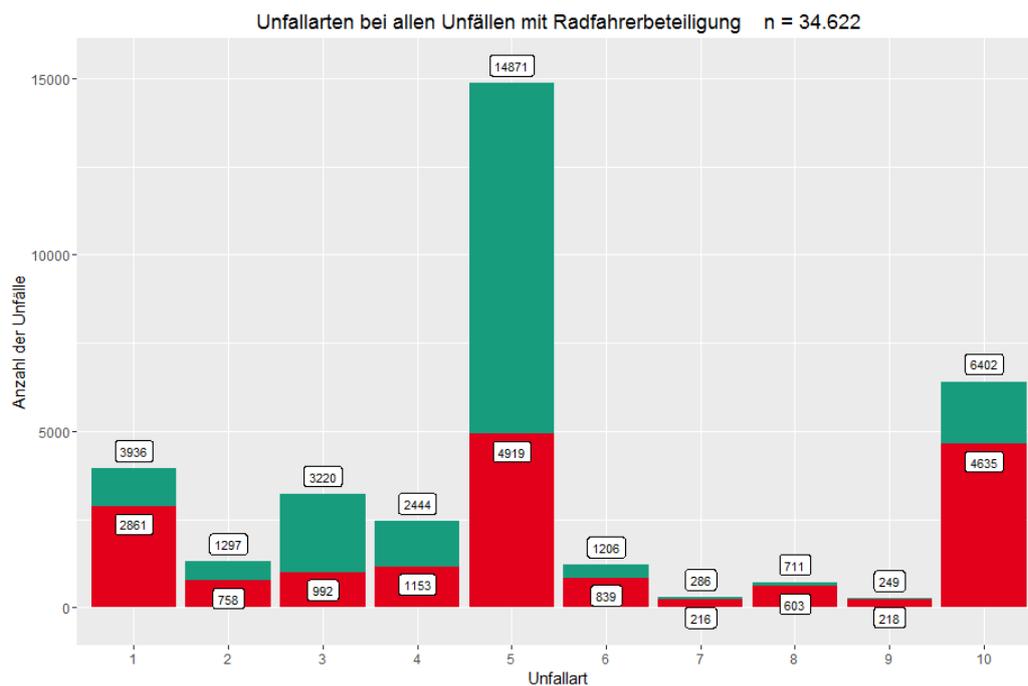


Abbildung 5: Unfälle in Sachsen 2010-2016: Unfallarten; Radfahrer als Unfallbeteiligter (grün) und als Unfallverursacher (rot)

Die aus den Unfalldatenbanken gefilterten Unfälle mit Radfahrerbeteiligung wurden anschließend für die Gefahrenstelle_Rad-Datenbank **mit Metadaten angereichert** und **georeferenziert**. Über die Metadaten (z.B. Unfallart und Unfalltyp) wird ein späteres Clustern der einzelnen Unfälle zu Gefahrenstellen möglich (gehäufte Unfälle gleicher Art am selben Ort innerhalb eines bestimmten Zeitraumes).

Die entstandene Datenbank wird in folgendem Kartenausschnitt exemplarisch dargestellt:

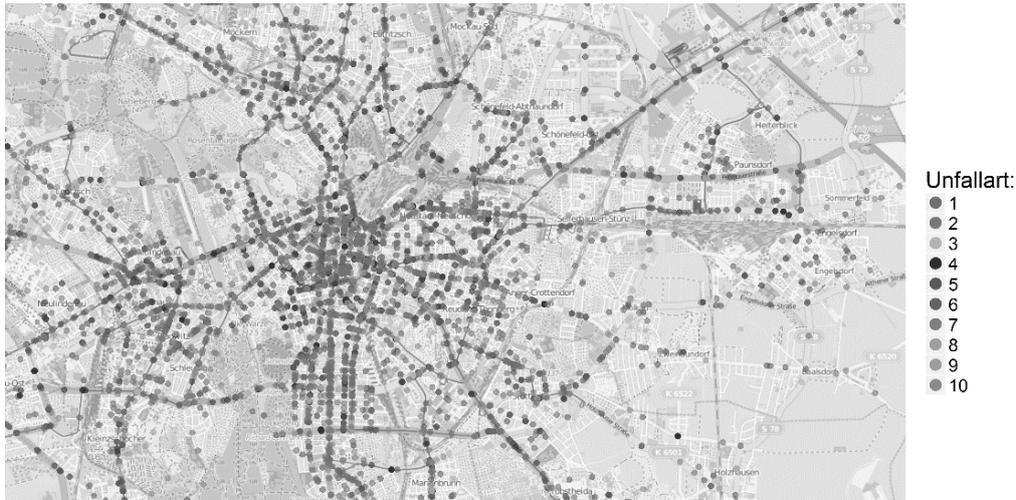


Abbildung 6: Unfälle nach Unfallart, Ausschnitt Leipzig

Die in AP1 entstandene Datenbank enthält abschließend die georeferenzierten Unfalldaten mit Radfahrer-beteiligung, angereichert mit Metadaten zu Unfallart und zum Unfalltyp. Die Datenbank ist eine der Grundlagen für AP 3, in der Gefahrenstellen auf Basis der Unfalldaten (AP1) und aufgezeichneten kritischen Situationen (AP2) erstellt werden.

1.2 AP 2: Verfahren zur Erkennung von kritischen Fahrmanövern

Ergänzend zur Identifikation von Gefahrenstellen aus Unfalldaten (AP1) wurde in AP2 ein Verfahren zum Erkennen von Gefahrenstellen aus Sensormustern entwickelt, um auch kritische Situationen, Beinahe-Unfälle und Alleinunfälle ohne polizeiliche Erfassung mithilfe einer **fahrradseitigen Sensorik** (z.B. Sensoren eines Fahrrad-Computers, eines E-Bike-Antriebs oder eines zur Navigation genutzten Smartphones) erkennen zu können. Parallel wurde in AP 4 eine prototypische Smartphone-App entwickelt, mit denen Daten erhoben werden konnten. Diese wurden in einem eigens entwickelten Web-Analyse-Tool geprüft und auf Kartenmaterial georeferenziert, um eine **Sensorevaluation** durchzuführen.

1.2.1 Datenerhebung

Für die Datenerhebung wurde eine Android App entwickelt mit der Smartphone interne Sensoren aufgezeichnet werden konnten. Diese Daten bilden den Grundbaustein für das Verfahren zur Erkennung von Gefahrenstellen. Durch die Entwicklung der App, auf die selber in 1.4 näher eingegangen wird, konnten bereits vorarbeiten in diesem AP erfolgen. Für die spätere Klassifikation ist es unabdingbar, dass den aufgezeichneten Sensorwerten ein sogenanntes Label (Beschreibung, Klasse) zugeordnet wird. Dies wird zum einen benötigt, um dem Klassifikationsalgorithmus zu erklären welche Daten er gerade verarbeitet und zum anderen, um diesen später genau zu validieren und zu testen. Die Zuordnung erfolgt dabei Zeitabschnittsweise. Das heißt jedem definiertem Zeitabschnitt T wird mit einer bestimmten Klasse versehen. Dies konnte sowohl in der App erfolgen als auch nachträglich mit Hilfe des Web-Analyse-Tools. In einer ersten Testreihe wurden die Daten von Mitarbeitern des IVI aufgezeichnet und direkt in der Android-App annotiert. Die Annotation erfolgte dabei über eine Geokoordinate, welche vom Nutzer in Form eines Markers gesetzt und danach mit einem Label versehen wurde. Die möglich auswählbaren Geokoordinaten konnten im besten Fall mit einer Rate von 10Hz aufgezeichnet werden, was einem Lokalisierungspunkt pro Sekunde entspricht.

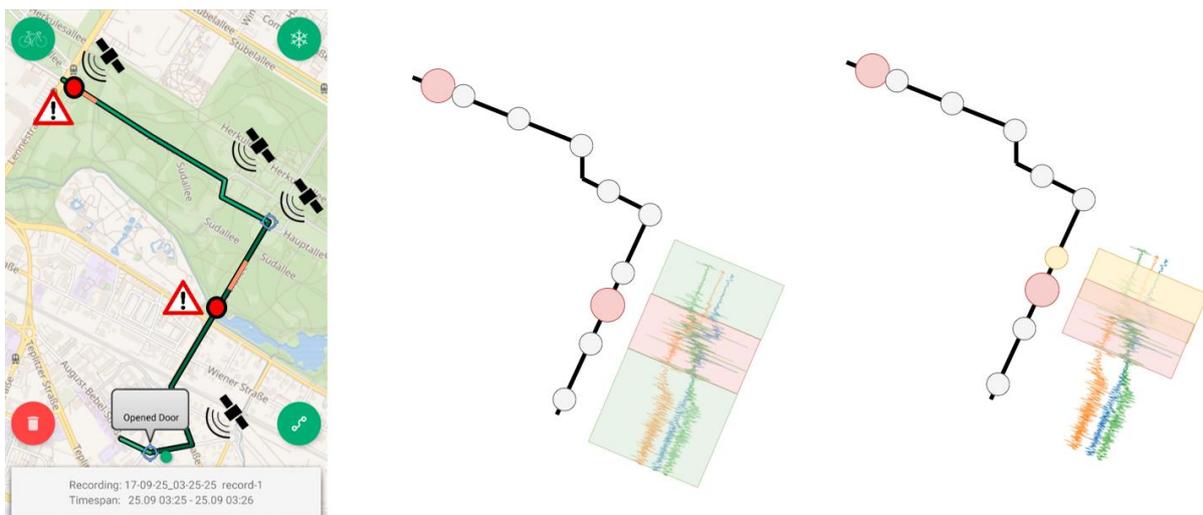


Abbildung 7 Annotierungsproblematik durch das geografische Referenzieren von Nutzer-Labels. Links: App-Aufnahme mit zwei Gefahrenpunkten (Rot). Mitte: Schematische Aufzeichnung der Lokalisierungen mit korrekter Annotation (Rot ist korrekt Gefahr und alles andere korrekt keine Gefahr). Rechts: Fehlklassifikation durch den nächsten Lokalisierungspunkt.

Es hat sich gezeigt, dass das geografische Referenzieren von Label Zuordnungen der Nutzer sehr fehleranfällig ist. In Abbildung 7 ist ein Screenshot der App dargestellt, mit der eine Aufnahme durchgeführt wurde. Die roten Punkte verdeutlichen reale Gefahrenpunkte. Wenn von der mittleren Grafik ausgegangen wird und die exakte Lokalisierung verwendet wurde, so ist der Gefahrenbereich (Rot) sowie der Nicht-Gefahrenbereich (Grün) korrekt gelabelt. Wenn aber wie im rechten Teil, eine Lokalisierung neben der Gefahr verwendet wird, oder es vielleicht auch gar keinen Lokalisierungspunkt exakt an der Stelle der Gefahr gibt, so kommt es zu falschen Labels (Gelb). Diese haben zur Folge, dass der Klassifikationsalgorithmus Nicht-Gefahren als Gefahren lernt und andersherum und somit mehr Fehler macht. Wie sich gezeigt hat, reicht die Auflösung der Lokalisierungsdaten nicht hinreichend aus, um darauf aufbauen korrekte Annotation durchführen zu können.

Daher wurden danach die Daten manuell anhand des Zeitstempels mit dem Web-Tool annotiert.

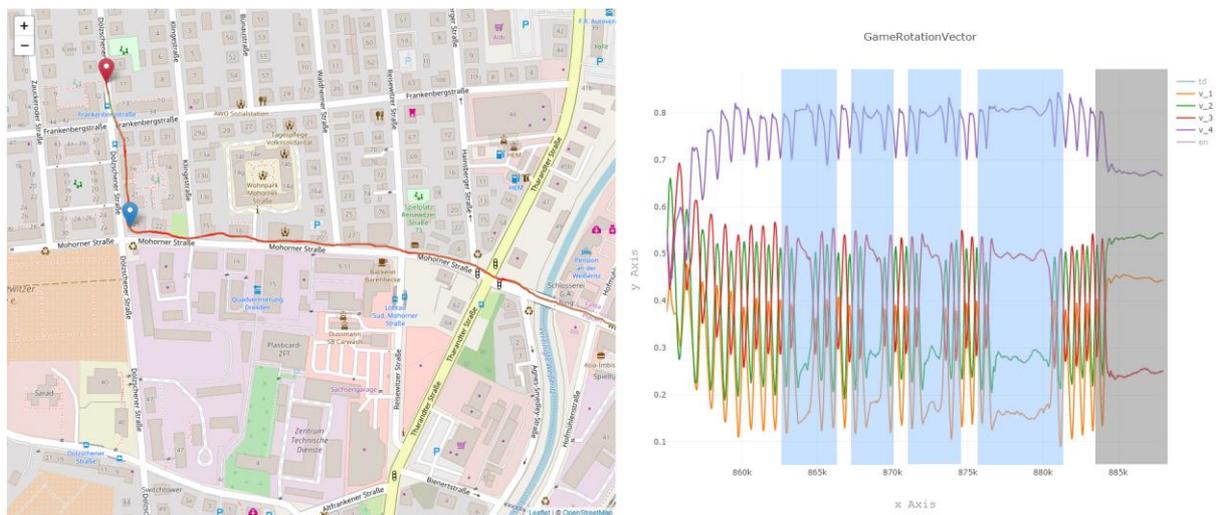


Abbildung 8: Web-Tool Zuordnung Scharfes Bremsen ohne Stillstand. [Links] Geschwindigkeitsprofil und Bereichsmarker, [Rechts] Sensorwerte mit markierten Bereichen in denen die Bremsungen stattgefunden haben.

Die Aufzeichnungen erfolgten weitestgehend unter laborhaften Zuständen. Spezifische Bewegungsmuster wurden hierfür auf Strecken ohne nennenswerten Verkehr aufgezeichnet und die Ausübung anderer fahrspezifischer Bewegung (Kurven, nach Hinten schauen, Abbiegezeichen setzen) wurde auf ein Minimum reduziert, um eine klare Unterscheidbarkeit in den Aufnahmen zu sehen und keine Fehler bei der Annotation zuzulassen. So wurde z.B. auf einem Streckenabschnitt von einem Kilometer mehrfach eine spezifische Gefahrensituation nachgestellt. Zwischen den Events kam es lediglich zu regulärem Anfahren. Dadurch konnten im Nachgang, wie in Abbildung oben rechts, die Events eindeutig ihren passenden Labels zugeordnet werden.

1.2.2 Evaluierung der Sensortechnik

Der erste Schwerpunkt des Arbeitspaketes lag auf der **Evaluierung der Sensortechnik**. Dafür wurden umfangreiche Recherchen und Sensordatenaufzeichnungen durchgeführt, um einen Überblick über die verschiedenen Sensormöglichkeiten zu gewinnen. Ein besonderer Fokus lag dabei auf der integrierten Smartphone-Sensorik und die Evaluierung der Position eines Smartphones während der Fahrt (am Lenker festgeklemmt, in der Hosentasche, im Rucksack usw.). In wie fern diese Rotationsabhängigkeit störend für den mathematischen Ansatz ist, musste zunächst untersucht werden. Die Sensoren in

Smartphones reichen von Bewegungssensorik¹ (Inertialsensorik), Positionssensorik² (Kompass und Magnetfeld) über Umgebungssensorik³ (Licht und Luftdruck) zu Geodatenensorik (GPS, Galileo).

Da eine genaue Lokalisierung für die Verortung der Bewegung notwendig ist, wurden die Lokalisierungsinformationen als unerlässlich angesehen. Die weitere Sensorevaluation wurde anhand der Kriterien *mögliche Abtastrate*, *Verfügbarkeit*, *physikalische Relevanz*⁴ und *visueller Prüfung anhand von exemplarischen Fahrscenarien wie Kurvenfahrten, Ausweich- und Bremsmanöver* durchgeführt.

Weiterhin wurde betrachtet inwiefern Sensoren miteinander korrelieren, um sich auf notwendige Informationen zu begrenzen. Je nach Klassifikationsalgorithmus ist es möglich, dass dieser, gewisse Zusammenhänge selber bestimmen kann. In Abbildung 9 sind zwei Korrelationsmatrizen mit verschiedenen Filtern (links: größer 0.5 (Korrelation vorhanden), recht: größer 0.75 (starke Korrelation)) gezeigt. Die meisten Korrelationen lassen sich insofern erklären, dass es physikalisch vorhandene Sensoren und virtuelle Sensoren gibt. Virtuelle Sensoren sind Algorithmen die verschiedenen anderen Sensoren kombinieren.

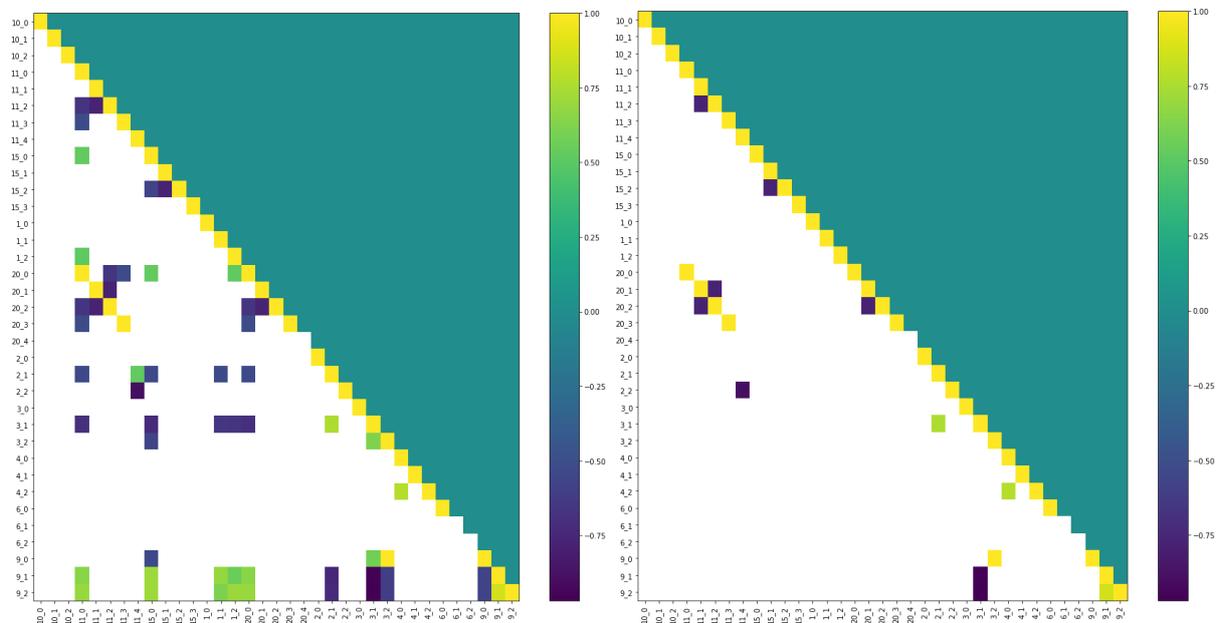


Abbildung 9: Korrelationsmatrix (Links: absoluter Wert > 0.5; Rechts: absoluter Wert > 0.75). Die Endungen „_0, _1, _2“ beschreiben die einzelnen Achsen eines Sensors. Ein Beschleunigungssensor misst beispielsweise in die drei Richtungen x, y, z. Die Nummer ist die ID des Android-Sensors⁵.

¹ https://developer.android.com/guide/topics/sensors/sensors_motion.html

² https://developer.android.com/guide/topics/sensors/sensors_position.html

³ https://developer.android.com/guide/topics/sensors/sensors_environment.html

⁴ Beschleunigung ist Teil jeder Bewegung

⁵ <https://developer.android.com/reference/android/hardware/Sensor.html>

Wie in den Abbildungen 8 und 10 zu sehen ist, wurden verschiedenen Fahrscenarien bezüglich der Sensoren untersucht. Daraus wurde ersichtlich, dass fahrspezifische Charakteristiken wie Richtungswechsel oder Bremsmanöver bezüglich unterschiedlicher Sensoren gut erkennbar sind. Diese Charakteristiken sind durch einen maschinellen Lernalgorithmus zur **Mustererkennung** identifizierbar, der anhand der aufgezeichneten und im Web-Tool manuell gelabelten Daten trainiert wurde.

Der Orientierungssensor (auch Kompass genannt) zeigt zwar klar, dass er zur Bestimmung von Fahrbewegungen verwendet werden kann, jedoch nicht verwendet wird, da dieser veraltet ist und perspektivisch nicht weiter unterstützt wird. Da dieser Sensor ein virtueller Sensor ist, welcher seine Werte durch eine Kombination von anderen Sensoren ermittelt ist dies aber kein Problem. Das magnetische Feld sowie der Rotationsvektor zeigen ähnlich klare Charakteristiken. Der Gravitationsensor und die lineare Beschleunigung sind auch virtuelle Sensoren, welche die Aufteilung der Komponenten einer Beschleunigung in horizontale und vertikale Richtung darstellen und somit sehr stark korrelieren. Um sich auf lediglich notwendige Sensoren zu begrenzen, wurde daher die reine Beschleunigung verwendet.

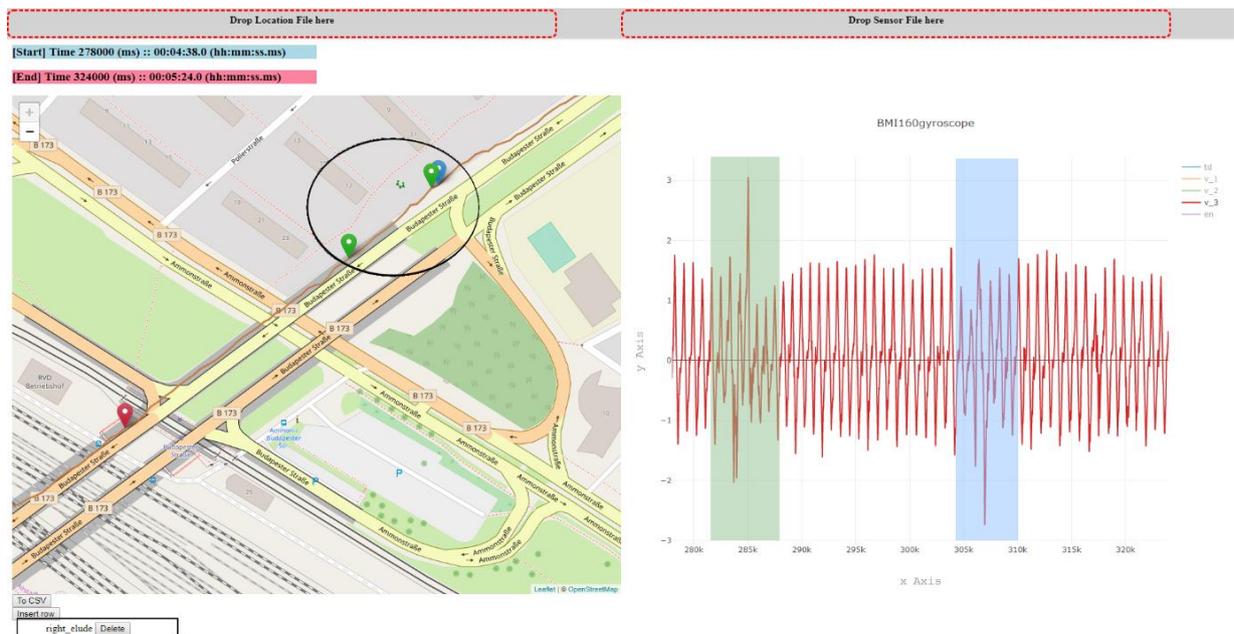


Abbildung 10: Zwei Ausweichmanöver (Grün: ausweichen im Rechtsbogen, Blau ausweichen im Linksbogen). Die beiden Grünen Marker zeigen den Bereich in dem das Grüne Ausweichmanöver stattgefunden hat.

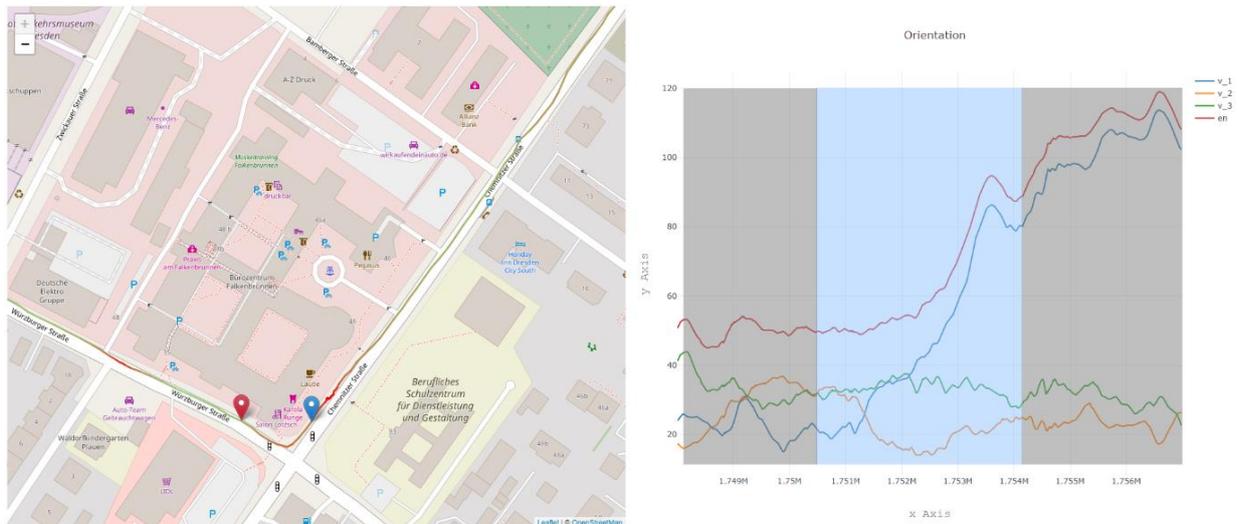


Abbildung 11: Darstellung eines Fahrausschnittes mit einer Rechtskurve in dem Bereich der beiden Marker. [links] Geschwindigkeitsprofilausschnitt, [rechts] Sensorwerte des Kompasses. Der blau markierte Bereich zeigt die Kurvenfahrt vom Blauen zum Roten Marker.

Folglich sind nachstehende Sensoren übriggeblieben, die im Weiteren für die Klassifikation von Bedeutung waren.

Location	Gyroscope	Acceleration
Rotation-Vector	Magnetic field	Pressure

1.2.3 Mustererkennung

Für die Erkennung von kritischen Fahrmanövern in Sensordaten wurde ein Verfahren basierend auf maschinellen Lernmethoden entwickelt. Dadurch können Sensordaten in einem Zeitabschnitt T bestimmte Klassifikationsmuster zugeordnet werden. Der Prozess ist vereinfacht in Abbildung 12 dargestellt. Sensordaten werden zunächst über eine entsprechende App aufgezeichnet und annotiert. Die Daten werden im nächsten Schritt in gleich große Blöcke aufgeteilt, damit der Klassifikationsalgorithmus einen konsistent großen Eingangsvektor hat. Der Lernalgorithmus versucht darauf folgend Gesetzmäßigkeiten in den gelabelten Daten zu ermitteln, um diese später für eine Klassifikation zu verwenden.

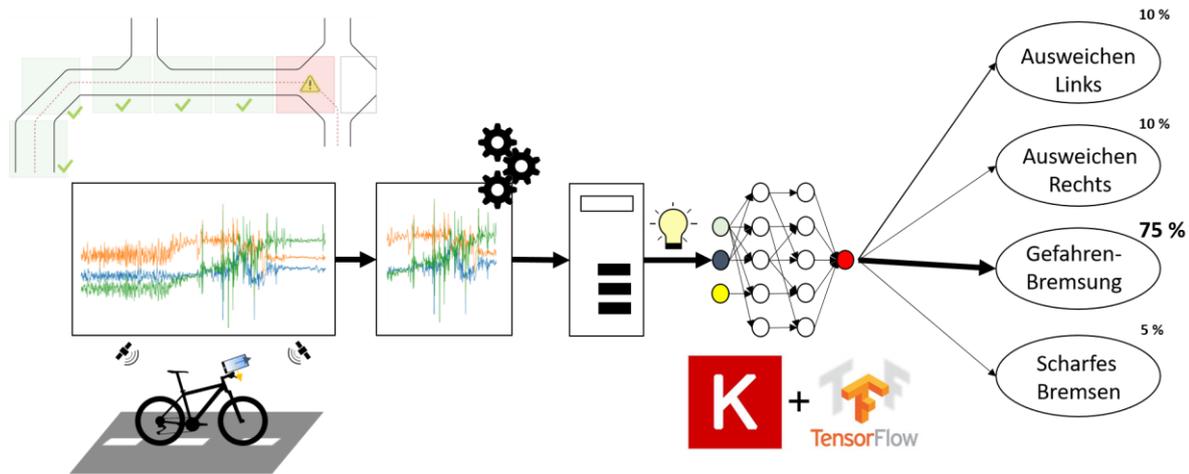


Abbildung 12 Vereinfachtes Konzept zur Identifikation von kritischen Gefahrenstellen

Es wurden verschiedene maschinelle Lernansätze getestet und hinsichtlich ihrer Portabilität auf mobile Endgeräte bewertet. Grundlegend unterscheiden sich die Ansätze in der Verwendung von Features (Merkmale) und im Klassifikationsalgorithmus selbst. Merkmale bilden den Eingangsdatenvektor für einen Algorithmus. Eine einfache Entscheidung ob ein Fahrer schneller als 30km/h fährt kann anhand der gegebenen Geschwindigkeit v getroffen werden oder aber auch über Zeit und Ort der Vergangenheit und Gegenwart (Zeitabschnitt). Wenn die Geschwindigkeit nicht vorhanden ist, kann diese aus den anderen beiden Größen abgeleitet werden und als eigenständiges Merkmal im Eingangsdatenvektor aufgenommen werden.

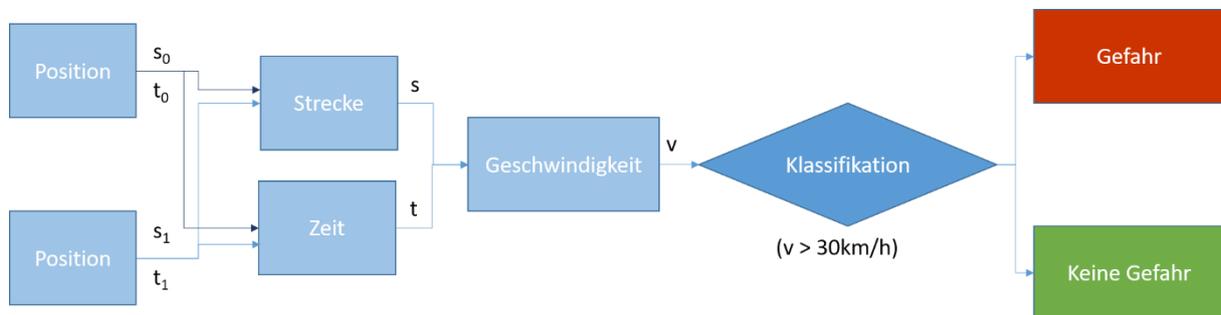


Abbildung 13 Klassifikation auf Basis eines Merkmals v oder der Ableitung dieses aus den Kenngrößen s und t über den Zeitraum T

Dieses Merkmal kann die Berechnungszeit als auch die Genauigkeit der Klassifikation verbessern. Neben Ansätzen die auf dem Feature Engineering aufbauen, wurden Algorithmen ausprobiert, die diesen Prozess automatisiert machen. Dies hat jedoch den Nachteil, dass kein Rückschluss auf die Wichtigkeit eines Merkmals gezogen werden kann, da nicht bekannt ist, welche Merkmale wie und in welcher Kombination intern eingehen.

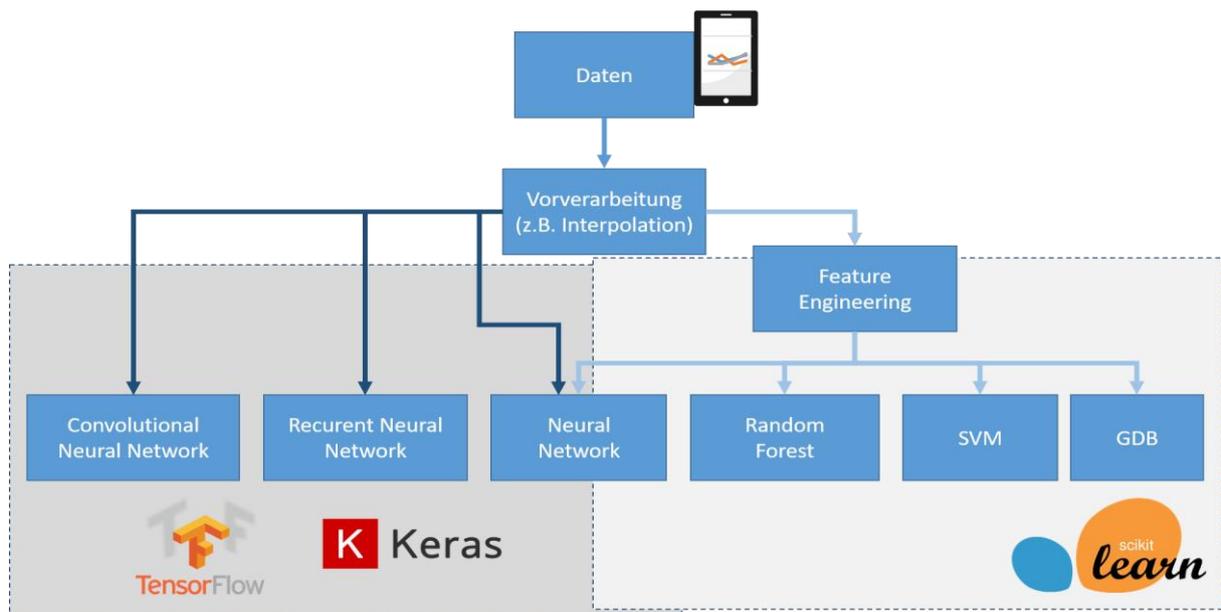


Abbildung 14 Algorithmische Ansätze zur Gefahrenerkennung

In Abbildung 14 sind die verschiedenen Ansätze gezeigt, welche zur Anwendung kamen. Auf der linken Seite sind die maschinellen Lernmethoden ohne Merkmalsgeneration und auf der rechten Seite diejenigen mit dargestellt. Für die Modellierung und Anwendung der maschinellen Lernmethoden kamen Keras⁶, Tensorflow⁷ und Sklearn⁸ zum Einsatz. Folgende Tabelle soll nochmal die wesentlichen Vor- und Nachteile der beiden Gruppen zeigen:

	Vorteile	Nachteile
Mit Merkmalen	<ul style="list-style-type: none"> Rückschlussmöglichkeiten auf charakteristische Merkmale 	<ul style="list-style-type: none"> Zeitaufwendig Portabilität Aufwändig, da Merkmalsgeneration auf dem Gerät implementiert werden muss
Ohne Merkmal	<ul style="list-style-type: none"> Schnelle Entwicklung Übertragung auf Mobilgeräte leicht, da Merkmalsberechnung entfällt 	<ul style="list-style-type: none"> Komplette Blackbox (Rückschlussfähigkeit kaum vorhanden)

Die wichtigsten Punkte bei der Evaluierung eines geeigneten Modells sind **Portabilität (Unterstützung verschiedener Plattformen, Speicherplatz), Genauigkeit, Fehleranfälligkeit, die Möglichkeit der kontinuierlichen Modellanpassung** sowie **Recheneffizienz**. Wie sich in der Projektlaufzeit gezeigt hat, sind die Vorteile von merkmalslosen Ansätzen so dominant, dass diese klar priorisiert werden sollten und

⁶ <https://keras.io/>

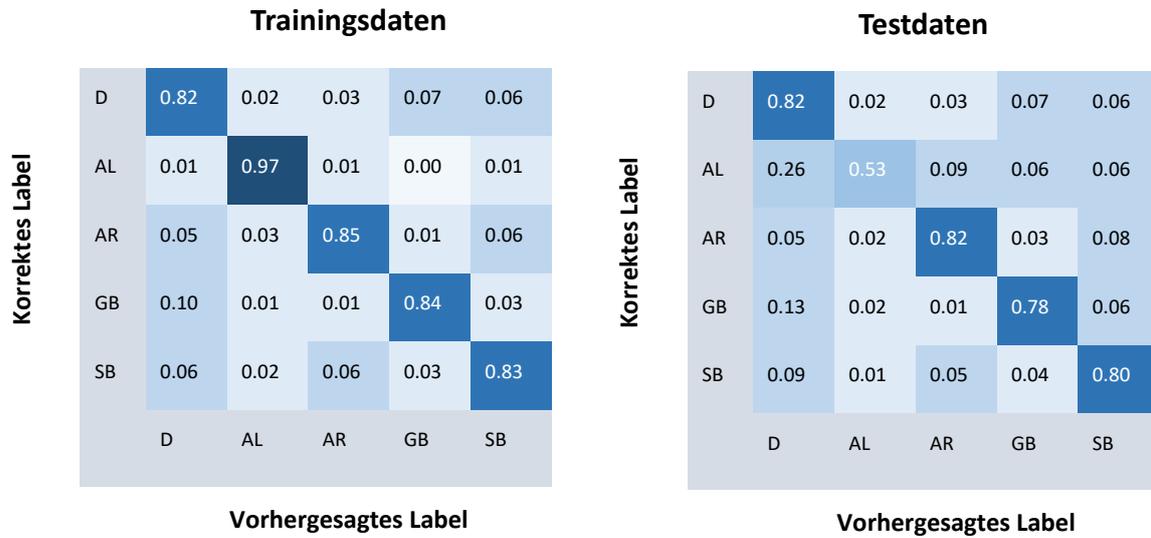
⁷ <https://www.tensorflow.org/>

⁸ <https://scikit-learn.org/stable/>

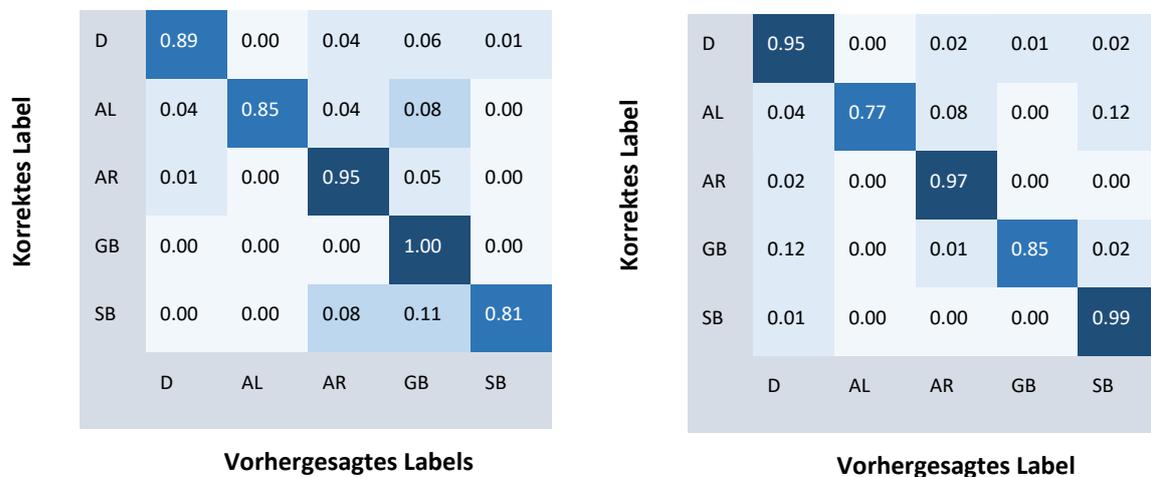
auch wurden. Klassische Verfahren wie Random Forrest, GDB und SVM haben basierend auf Merkmalen klar den Vorteil, dass diese auch beschreibbar sind und am Ende gesagt werden kann, welcher Sensor mit welchem Merkmal wie sehr in die Klassifikation eingeht. Beispielsweise hat sich bei der Evaluation gezeigt, dass bestimmte Sensoren wie Beschleunigung, Gyroskop und Kompass die charakteristischsten Merkmale aufweisen. Aber es steht in keinem Verhältnis zum Aufwand. Gerade da der Prozess des Feature Engineering sehr zeitaufwändig ist und auch nicht klar ist, ob alle notwendigen Merkmale vorhanden sind. Weiterer (perspektivischer) Nachteil ist die Implementierung für verschiedene Endgeräte. Die Berechnung der Merkmale muss folglich für verschiedene Betriebssysteme zur Verfügung stehen und energieeffizient erfolgen.

Der merkmalslose Ansatz beseitigt viele dieser Probleme. Ein neuronales Netz kann dabei intern Merkmale kombinieren und neue Merkmale schaffen die zur Klassifikation beitragen. Dadurch muss dieser Schritt nicht separat im Feature Engineering auf dem Endgerät passieren. Es muss lediglich das Klassifikationsmodell auf dem jeweiligen System angesprochen werden (was mit Keras sowohl für iOS als auch Android machbar ist) und mit den Sensordaten gespeist werden. Ein weiterer Vorteil eines neuronalen Netzes ist es, dass dieses kontinuierlich weiter trainiert werden kann. Klassische Verfahren haben oftmals den Nachteil das sie initial auf der gesamten Datenmenge lernen und dies auch wiederholt durchführen müssen wenn sich die Datenbasis ändert.

Folgende Tabellen zeigen Konfusionsmatrizen in denen dargestellt wird wie genau welches Label klassifiziert wurde. Dabei wurden als mögliche Klassen Fahrmanöver gewählt, die Basismuster komplexerer Vorgänge sind. Wenn ein Pkw von rechts kommt und die Vorfahrt missachtet und der Radfahrer ausweichen muss, so ist das Ausweichen nach Links klar charakteristisch für diesen Vorgang. Für die folgende Auswertung wurden die Basismuster Ausweichen Links (AL), Ausweiche Rechts (AR), Gefahrenbremsung (GB, mit Stillstand), Scharfes Bremsen (SB, kurzes starkes Abbremsen ohne folgenden Stillstand) und Default (D, alles andere). Die ersten beiden Tabellen zeigen die Ergebnisse für ein neuronales Netz, welches mit 1012 Merkmalen trainiert wurde, wovon effektiv 84 Merkmale in die Klassifikation mit eingegangen sind, da als Vorverarbeitungsschritt noch eine Principle Component Analysis (PCA) angewendet wurde, um den Merkmalsraum zu reduzieren und die Kalkulation des Klassifikationsmodells zu beschleunigen.



Zum Vergleich sind im Folgenden die Konfusionsmatrizen für ein VGG-Net⁹ basierendes Convolutional Neural Network (links) und ein triviales neuronales Netz (rechts) dargestellt. Mit einem klar geringeren Entwicklungsaufwand konnten zugleich bessere Ergebnisse erzielt werden, was klar für den merkmalslosen Ansatz spricht.



Für das Projekt wurde auf Basis dieser Erkenntnisse ein Klassifikationsmodell zur Erkennung von kritischen Basisbewegung entwickelt.

⁹ [Very Deep Convolutional Networks for Large Scale Image Recognition](#), Simonyan and Zisserman (2014).

1.3 AP 3: Fusionierung der Datenquellen und Aggregieren zu Gefahrenstellen

Im AP 3 wurde ein Konzept zur Fusionierung von Unfalldaten, kritischen Situationen aus Sensormustern sowie kontextuellen Umfeld-Daten erarbeitet und deren Austauschformate und Schnittstellen spezifiziert. Der Implementierung der Datenfusion folgte das Zusammenfassen der Gefahrenstellen zu Clustern, damit auf dieser Basis die Clusterprojektion erfolgen konnte. Um eine einfache und weitreichende Nutzung der Daten gewährleisten zu können, wurde im letzten Schritt dieses AP die Bereitstellung der Daten behandelt.

1.3.1 Fusionierungskonzept

In Abbildung 15 ist das vereinfachte Fusionierungskonzept dargestellt, welches folgende Punkte umfasst. Polizeilich erfasste Unfälle mit Fahrradbeteiligung aus den Unfalldatenbanken einzelner Bundesländer wie sie in AP 1 analysiert wurden. Sensorisch erfasste kritische Situationen, welche mit dem Konzept aus AP 2 ermittelt werden konnten. Sowie den **kontextuellen Umfeld-Daten** zur Anreicherung der bestehenden Daten, um weitere Attribute, damit genauere Rückschlüsse über die bereits vorhandenen Informationen hinaus möglich sind.

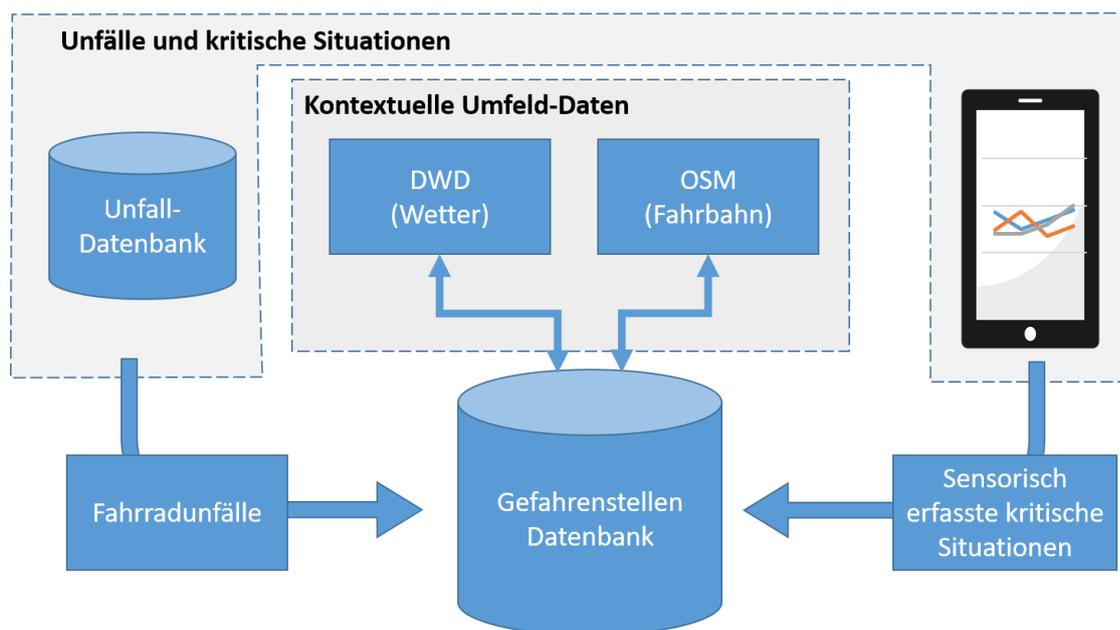


Abbildung 15: Fusionierungskonzept der Datenquellen

Eine Anbindung durch kontextuelle Umfeld-Daten, insbesondere aus der mCLOUD, wurde bereits im ersten Berichtszeitraum durchgeführt, indem Informationen des Deutschen Wetterdienstes (DWD)¹⁰ in Intervallen abgefragt und in die Datenbasis integriert werden können.

¹⁰ <https://www.dwd.de>

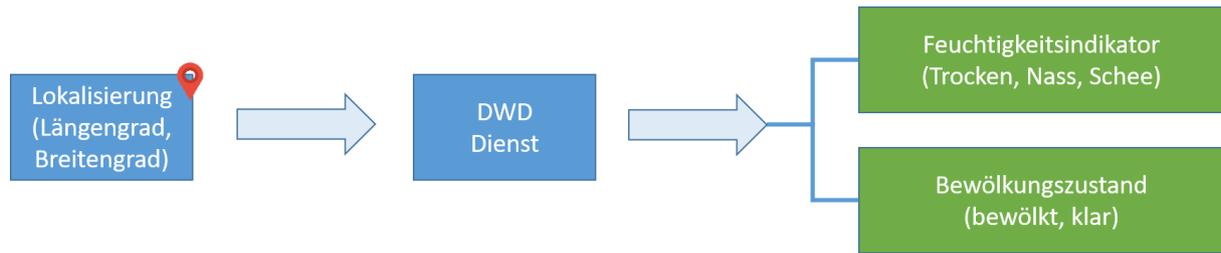


Abbildung 16 DWD Dienst

Um weitere potenzielle Aufschlüsse zu zeigen, wurden weitere Umfeld-Daten analysiert. Mit Hilfe von OpenStreetMap¹¹ Karten können dadurch auch jedem Schwerpunkt anhand der Lokalisierungsinformation weitere Informationen hinzugefügt werden.

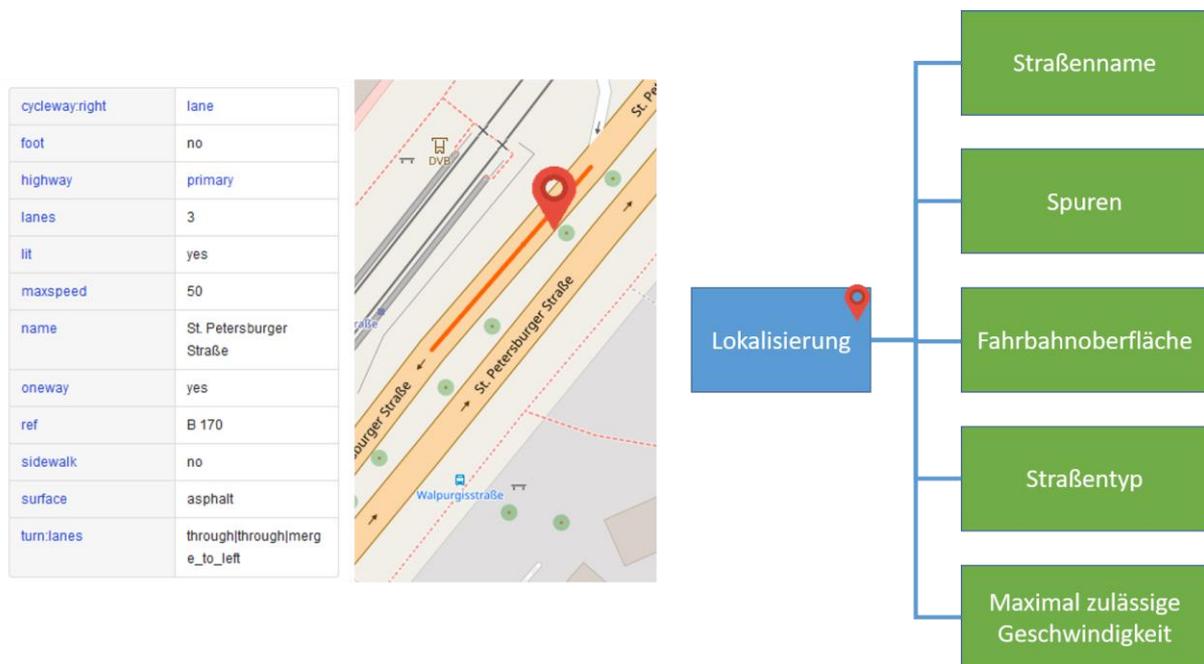


Abbildung 17 OSM Dienst

Hierdurch ergeben sich nützliche Informationen zu Fahrbahnoberfläche (Asphalt, Kopfsteinpflaster), Straßentyp (Hauptstraße, Nebenstraße, Feldweg), maximal zulässige Geschwindigkeit und viele mehr. Mit Hilfe der zahlreichen Zusatzinformationen, können Rückschlüssen wie

„In einem Cluster sind alle Unfälle auf Kopfsteinpflaster und bei Regen passiert. Die Unfallgefahr geht somit von der Fahrbahnoberfläche aus, da eine erhöhte Rutschgefahr besteht.“

gezogen werden. Die Kontext-Dienste stehen als eigenständige Anwendungen bereit und können über API-Schnittstellen angesprochen werden. Dadurch ergeben sich folgende Informationen die einem Schwerpunkt zugeordnet werden können.

¹¹ <https://www.openstreetmap.org>



Abbildung 18 Schwerpunktinformationen

1.3.2 Clusterung

Singuläre Unfallpunkte sind eher ungeeignet für Fahrerassistenzsystem, da sie nicht repräsentativ zeigen wo Schwerpunkte (Clusters) vorliegen und teilweise auch nur temporäre Gefährdungspunkte widerspiegeln. Wenn es an einem speziellen Ort einen einfachen Unfall gibt, weil dort ein Fahrfehler gemacht wurde, weil beispielweise der Fahrer unter Alkoholeinwirkung stand, so kann in dieser Stelle von keiner allgemeinen Gefahr für andere Radfahrende ausgegangen werden. Wenn aber auf einem Streckenabschnitt oder einem Kreuzungspunkt eine signifikante Häufung von Unfällen vorhanden ist,

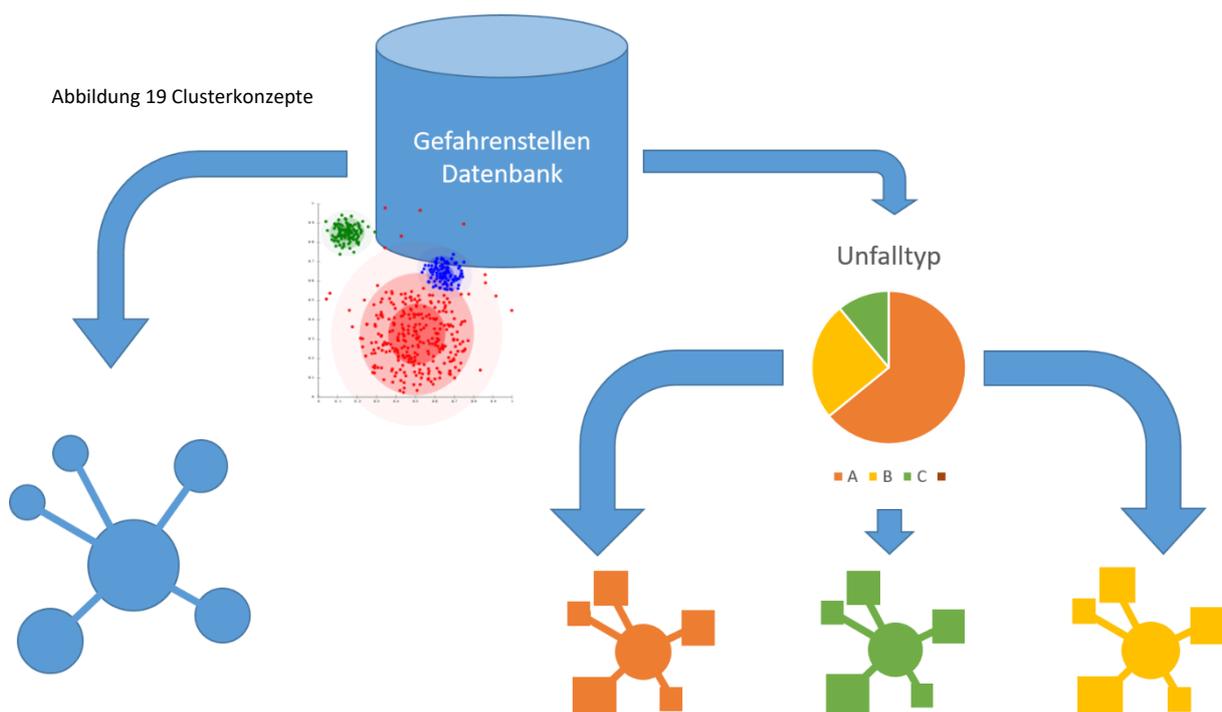


Abbildung 19 Clusterkonzepte

so kann eine allgemeine Gefahr angenommen werden. Deshalb wurden im nächsten Schritt Gefahrenstellen zu Häufungspunkten in Form von Clustern zusammengefasst. Für die Clustering wurden zwei Konzepte durchgeführt. Eine rein geobasierte Clusteranalyse sowie eine mit vorgelagerte Clustering nach Unfallhäufungen.

Bei der **rein geobasierten Clusteranalyse** wurde ein DBSCAN-Algorithmus verwendet, mit dem eine Häufung basierend auf Geodaten hinsichtlich der *Punktmenge* in einem Cluster und der *minimalen Distanz* erfolgte.

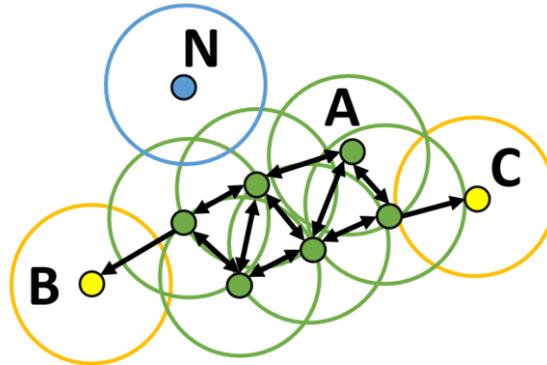


Abbildung 20 DBSCAN. Punkte bei A sind Kernpunkte. Punkte B und C sind dichte-erreichbar von A und dadurch dichte-verbunden und gehören zu dem gleichen Cluster. Punkt N ist weder ein Kernpunkt, noch dichte-erreichbar, also Rauschen. (=3 oder =4)¹²

Bei der Vorfilterung nach **Unfalltypähnlichkeiten** wurden die Unfalldaten vor dem geodatenbasierten Cluster nach den Attributen „Unfalltyp“ und „Unfallart“ in hierarchische Cluster zusammengefasst. Dabei wird gemäß Unfalltypenkatalog¹³ von Folgender Terminologie ausgegangen.

ID	Unfallart
1	anfährnt, anhält oder im ruhenden Verkehr
2	Vorrausfährt oder wartet
3	Seitlich in gleicher Richtung
4	Entgegenkommt
5	Abbiegt, einbiegt oder kreuzt
6	Fußgänger
7	Hindernis
8	Rechts
9	Links
10	Sonstige

ID	Unfalltyp
1	Fahrerunfall
2	Abbiegeunfall
3	Einbiegen/Kreuzen
4	Überschreiten Unfall
5	Ruhender Verkehr
6	Längsverkehr
7	Sonstiger Unfall

¹² <https://de.wikipedia.org/wiki/DBSCAN#/media/Datei:DBSCAN-Illustration.svg>

¹³ https://udv.de/sites/default/files/tx_udvpublications/unfalltypen-katalog_udv_web_2.pdf

Für alle möglichen Kombinationen können die prozentualen Anteile der Gesamtmenge bestimmt werden, anhand derer sich die größten Cluster beschreiben lassen. Das sind folgende.

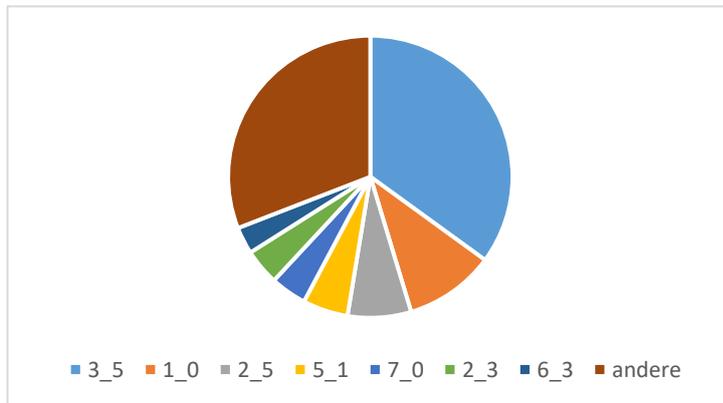


Abbildung 21 Unfalltyphäufungscluster nach *Unfalltyp* und *Unfallart* eg.: 3_5

Für die einzelnen Vor-Cluster wird anschließend mit dem bereits genannten DBSCAN Algorithmus eine Geodaten-Clustering durchgeführt. Dadurch ergeben sich hunderte Gefahrencluster im Anwendungsgebiet.

1.3.3 Bereitstellung

Die resultierenden Informationen werden im **GeoJSON-Format** bereitgestellt. Dieses ist ein offenes Format zur Repräsentation von geografischen Daten, welches von fast allen Karten-Anwendungen unterstützt wird und somit einen möglichst breit gefächerten Anwendungsraum ermöglichen. Sowohl in der prototypischen Test-App als auch in den verschiedenen Webtools kommt das Format auf Grund seiner einfachen Handhabung zur Anwendung. Damit erfüllt das Format alle notwendigen Kriterien für zukunftsorientierte Anwendungen.

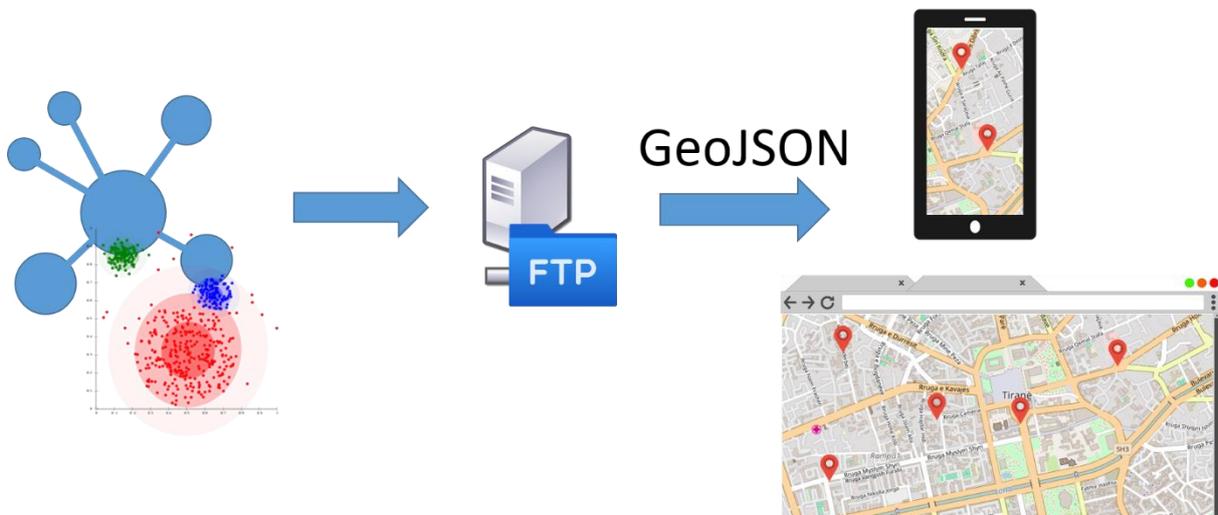


Abbildung 22 Bereitstellungskonzept mittels FTP Server und GeoJSON

1.4 AP 4: Prototypische Umsetzung und Demonstration

Zur Demonstration der Ergebnisse aus den vorhergehenden Arbeitspaketen und zum Aufbau einer initialen Datenbasis an Gefahrenstellen durch Sensoraufzeichnungen wurde eine prototypische Android Smartphone-Anwendung zur Datenerfassung erstellt. Das AP wurde bereits im ersten Berichtszeitraum begonnen, um die Smartphone-seitigen Sensoren in AP 2 zu evaluieren und Testdaten erheben zu können. Damit wurde eine Grundlage für das AP 4 (Prototypische Umsetzung und Demonstration) geschaffen, welche sich mit Aspekten zur Kartendarstellung, der Aufnahme von Sensordaten und deren Verarbeitung beschäftigt. Weiterhin kann die Anwendung genutzt werden, um eine Annotation (manuelles Labeln) der aufgezeichneten Fahrt durchzuführen und somit wichtige Stellen im Datensatz für AP2 zu kennzeichnen. Wie in AP 2 gezeigt, ist dies aber mit Fehlern verbunden, was zu einer falschen Datenbasis führen kann.

In Abbildung 23 sind verschiedene Oberflächen der Anwendung dargestellt. Auf dem Hauptbildschirm links findet die Aufnahme und Visualisierung statt. Weiterhin werden Informati-

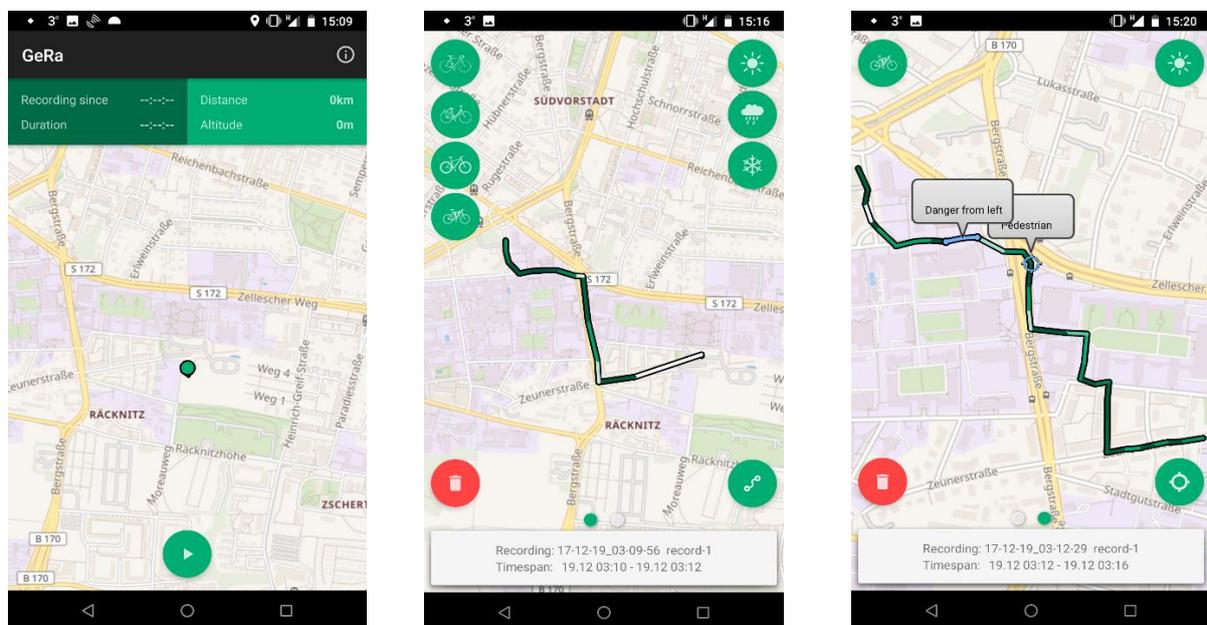


Abbildung 23: Demo-App [Links] Hauptbildschirm [Mitte] Annotiermodus (unbearbeitet) [Rechts] Annotiermodus (bearbeitet)

onen bezüglich Zeit, Strecke und Dauer der Aufnahme dargestellt. Die mittlere Abbildung zeigt den Annotationsmodus in dem auch Informationen zum Fahrradtyp und Wetter mit einfließen können. Die Annotation kann punkt- oder linienförmig erfolgen. Ein Beispiel zeigt die rechte Abbildung, welche verschiedene kritische Situationen darstellt.

Das Verfahren zur Erkennung von kritischen Situationen durch Auswertung von Sensordaten wurde prototypisch in eine Smartphone-Anwendung integriert, um die Funktionstüchtigkeit des Verfahrens zu demonstrieren. Konzept und Kommunikation sind in Abbildung 24 dargestellt.

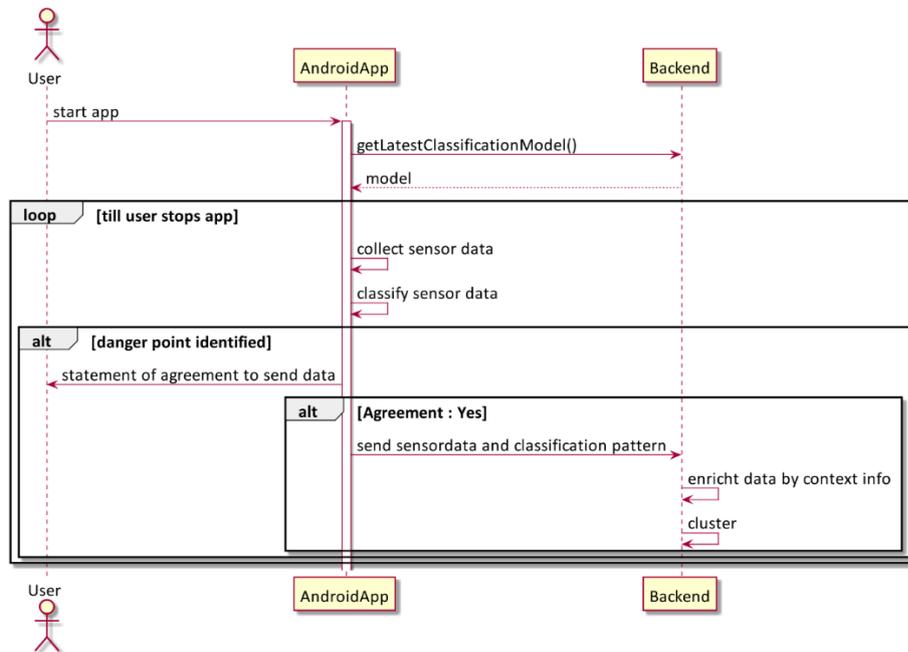


Abbildung 24 Klassifikation auf dem Smartphone

Jedoch wurde vom zuerst beschriebenen Konzept abgewichen, um effektiver mit den Daten arbeiten zu können und das Klassifikationsmodell und seine benötigten Vorverarbeitungsschritte auszulagern. Der Nutzer wird zum App Start gefragt ob er die Einverständniserklärung akzeptiert und nur, wenn er dies tut kann die App verwendet werden. Die App dient in diesem Konzept nur zur Datenvisualisierung und –erhebung. Die Daten werden zerstückelt an den Server gesendet und dort verarbeitet. Die Cluster und Klassifikationsergebnisse können in der Anwendung dargestellt werden.

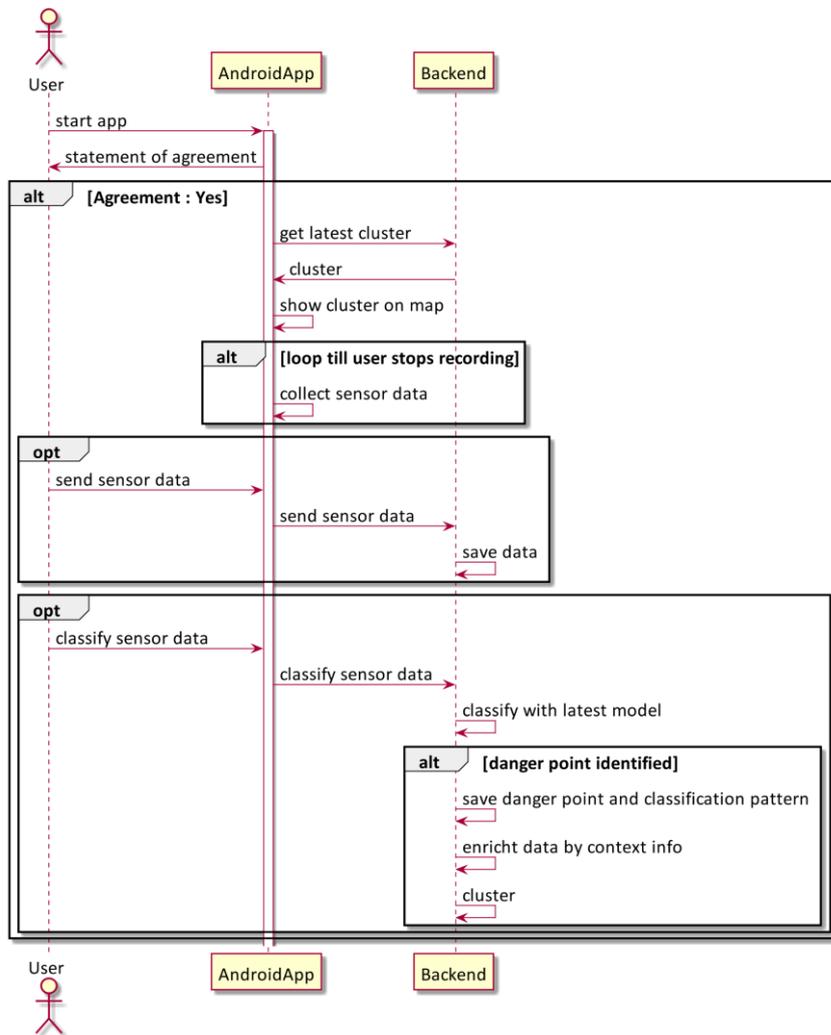


Abbildung 25 Externe Klassifikation im Backend

Beide Konzepte lassen sich problemlos verwenden, wodurch eine effizientere Verarbeitung der Daten erfolgen konnte. Der Nutzer hat mit seiner Einwilligung bestätigt, dass die Daten anonymisiert an das Fraunhofer gesendet werden, sofern er den Prozess durch betätigen eines Buttons in der App und nochmaliger Bestätigung verifiziert. Die Daten werden ausschließlich für die Ermittlung eines Klassifikationsmodells gemäß AP 2 verwendet. Von den erhobenen Daten werden auch nur Nutzdaten an den Sever gesendet, um sowohl Bandbreite zu sparen als auch den Datensatz zu zerteilen und mit unterschiedlichen anonymisierten IDs an den Server zu senden, damit keinerlei Personenbezogene Daten ableitbar sind.

Wie in AP 3 beschrieben, werden die als Gefahrenpunkte klassifizierte Daten im nächsten Schritt durch Kontextdienste mit weiteren Informationen angereichert. Eine Neu-Clusterung der Daten erfolgt automatisch einmal pro Woche. Die strukturierten, klassifizierte und verorteten Daten werden anschließend in das XML-basierte OSM-Format GeoJson konvertiert. Dazu wurde eine Komponente auf dem Server entwickelt und ihr regelmäßiger Start veranlasst. Basierend auf diesem Format können die Daten für vielfältige Zwecke genutzt werden. Sie stehen zur Weiterverwendung in der mCLOUD zur Verfügung können aber auch in OSM-Karten integriert werden. Als Schnittstelle dient ein FTP-Server, über den die Daten jederzeit abgerufen werden können.

Von einer umfangreicheren Evaluation mit Testnutzern wurde am Ende abgesehen, da kein Mehrwert für das Projekt ersichtlich war. Die App diene ausschließlich der Demonstration der Ergebnisvisualisierung auf dem Smartphone.

2 Vergleich Stand des Vorhabens mit Arbeits-, Zeit- und Finanzierungsplanung

Gegenüber der ursprünglichen Projektplanung haben sich keine nennenswerten Änderungen ergeben. Ein geringer Teil des Mittelbedarfs aus 2017 wurde nach 2018 verschoben und bis Februar 2018 ausgeglichen.

3 Änderungen in der Zielsetzung

Gegenüber der ursprünglichen Zielsetzung haben sich kleine Änderungen ergeben. Wie erst geplant, sollte die Gefahrenstellenerkennung Punkte ermitteln und diese jeweils automatisiert einen Unfalltyp und Unfallart zuweisen. Dies war auf Grund der zu geringen und wenig detaillierten Datenbasis nicht möglich. Weiterhin wurde von einer umfangreicheren Evaluation der Test-App durch Testnutzer auf Grund dieses Umstandes, und der Tatsache das der Aufwand und der Nutzen in keinem Verhältnis gestanden hätten, abgesehen.

4 Ergebnisse Dritter mit Relevanz für das Vorhaben

Im Berichtszeitraum sind keine Schutzrechte und Ergebnisse Dritter mit Relevanz für das Vorhaben bekannt geworden.

Es sind im Berichtszeitraum zwei Forschungsvorhaben gestartet, mit denen ein Austausch über mögliche Kooperationen stattfindet. Dazu zählt das im mFUND geförderte Projekt *Movebis*¹⁴ und das im NRVP geförderte Projekte RadVerS¹⁵.

5 Öffentlichkeitswirksame Maßnahmen und Austausch mit anderen Initiativen

- 27.09.2017 mFUND-Konferenz „Ein Jahr digitale Innovationen für die Mobilität 4.0“ Präsentation im Workshop „Daten für Verkehrssicherheit“
- 27.11.2017 Präsentation und Austausch im Forschungsbegleitkreis NRVP
- 16.10.2018 mFUND-Konferenz "Daten als Motor für die Mobilität 4.0" Präsentation im Workshop „Daten für die Fahrradnutzung und die Radverkehrsplanung“
- 29.03.2019 Präsentation und Austausch im Forschungsbegleitkreis NRVP

Während der mFUND-Konferenz 2017 wurde das Projekt *Gefahrenstelle_Rad* dem interessierten Fachpublikum vorgestellt und der Austausch mit anderen Projekten initiiert. So konnten Kontakte u.a. zum Movebis-Projekt und zum Deutschen Städte- und Gemeindebund (DStGB) geknüpft werden.

¹⁴ <https://www.bmvi.de/SharedDocs/DE/Artikel/DG/mfund-projekte/verbesserung-der-fahrradinfrastruktur-movebis.html>

¹⁵ <https://nationaler-radverkehrsplan.de/de/praxis/mit-smartphones-generierte-verhaltensdaten-im-0>

Das Gefahrenstelle_Rad-Projekt wurde weiterhin in den Forschungsbegleitkreis „Infrastruktur“ des NRVP aufgenommen, in dem sich NRVP-Projekte austauschen können.

Das Movebis Projekt hat im Bearbeitungszeitraum eine umfangreiche Datenbasis aufgebaut, welche für das Projekt Gefahrenstelle_Rad interessant war, sich aber leider nicht als hilfreich erwiesen hat: Die in den Daten möglicherweise aufgezeichneten kritischen Situationen oder Unfälle wurden nicht (durch Nutzer oder Projektmitarbeiter) klassifiziert/gelabelt, was auch nicht im Rahmen des Movebis-Projektes eingeplant war. Somit konnte der Datensatz weder als Trainings- bzw. Testdatensatz zur Validierung der im Gefahrenstelle_Rad entwickelten Methoden genutzt werden.

6 Fortschreibung des Verwertungsplans

6.1 Erfindungen, Schutzrechtsanmeldungen und erteilte Schutzrechte

Im Berichtszeitraum wurden keine Erfindungen angemeldet und keine Schutzrechte erteilt.

6.2 Wirtschaftliche Erfolgsaussichten nach Projektende

Die in diesem Projekt entstandene Gefahrenstellen-Datenbank ist für mehrere wirtschaftliche Anwendungsmöglichkeiten einsetzbar. Dazu zählen beispielsweise:

- 1) **Navigationsanwendungen/Assistenzsysteme für Rad- und Pkw-Fahrer:** Während der Fahrt kann ein Rad/Pkw-Fahrer vor einer vorausliegenden Gefahrenstelle gewarnt werden, wenn die aktuelle Geschwindigkeit zu hoch oder die Witterungsbedingungen ungünstig sind. Für die Weiterentwicklung der Gefahrenstellen-Datenbank ist dieser Anwendungsfall im Besonderen interessant, da Navigationsanwendungen (Smartphone-Apps, Fahrrad-Computer, E-Bike-Computer) potenziell kritische Situationen aufzeichnen und an die Gefahrenstellen-Datenbank zurücksenden können, um diese zu aktualisieren und zu erweitern. Auf diese Weise sollen perspektivisch großflächig aktuelle Gefahrenstellendaten bereitstehen.
- 2) **Online-Radrouten-Planer** und Kartendienste für Radfahrer: Bei der Berechnung von Radrouten werden Gefahrenstellen berücksichtigt, um eine möglichst sichere Route zu wählen.
- 3) **Stadt- und Verkehrsplanung:** Die Datenbank kann einen Beitrag dazu leisten, Gefahrenstellen bei zukünftigen verkehrsplanerischen Maßnahmen zu berücksichtigen bzw. geplante Maßnahmen zu priorisieren. Bereits umgesetzte Maßnahmen können sich mit Hilfe der Datenbank evaluieren lassen, in dem die „Gefährlichkeit“ vor und nach der Umsetzung verglichen wird.

Dass insbesondere die **erste** Anwendungsmöglichkeit besonders relevant ist, zeigte die Abbildung 3 aus AP 1: Ca. 50% der Unfälle mit Radfahrerbeteiligung werden von diesen selbst verursacht. Eine entsprechende Assistenzfunktion eines Fahrrad-Navigationssystems oder einer Smartphone-App zum Warnen vor Gefahrenstellen könnte zu einer **erheblichen Senkung von Unfällen** beitragen.

Während des Berichtszeitraums gab es zu diesen Anwendungsmöglichkeiten regen Austausch mit interessierten Firmen, unter anderem der Bike Citizens Germany GmbH und der Robert Bosch GmbH. Von diesen Firmen wurde das Potenzial der Gefahrenstellen-Datenbank für die Erweiterung ihrer Produkte um eine entsprechende Assistenzfunktion erkannt. Besonders die potenzielle Integration in die

Bosch E-Bike-Systeme könnte zu einer größeren Marktdurchdringung einer entsprechenden Assistenzfunktion und somit auch zu einem positiven Effekt auf die Unfallstatistiken führen.

6.3 Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende

Die wissenschaftliche Verwertung erfolgt durch Veröffentlichung/Präsentationen der Forschungsergebnisse und der entwickelten Methoden auf relevanten Fachkonferenzen. Das Fraunhofer IVI baut durch das Vorhaben seine Kompetenzen im Bereich der Mobilitätsdaten weiter aus, um für die verschiedenen Akteure in der Mobilitätsbranche auch zukünftig ein attraktiver Forschungs- und Entwicklungspartner zu sein.

6.4 Wissenschaftliche und wirtschaftliche Anschlussfähigkeit für eine mögliche notwendige nächste Phase bzw. die nächsten innovatorischen Schritte zur erfolgreichen Umsetzung der FE-Ergebnisse

Eine unmittelbare wirtschaftliche Verwertung der Gefahrenstellen-Datenbank für die skizzierten Anwendungsmöglichkeiten 1) und 3) aus 6.2 ist nach Projektende noch nicht direkt gegeben, da die entsprechenden Anwendungen bzw. Prozesse zur Nutzbarmachung der Daten für diese Anwendungsfälle noch nicht vorhanden sind. Für eine Assistenzfunktion entsprechend 1) werden beispielsweise zusätzliche Modelle und Algorithmen benötigt, die während der Fahrt auf Basis der Gefahrenstellen-Datenbank die Entscheidungen treffen, ob eine Gefahr eintritt (beispielsweise durch zu hohe Geschwindigkeit) und wie vor einer Gefahrenstelle gewarnt werden muss, um eine kritische Situation zu vermeiden. Die Erforschung dieser Themen und die Entwicklung entsprechende Modelle und Algorithmen wird beispielsweise im Kontext des vom Fraunhofer IVI koordinierten F&E-Projekt Rad^{IM}Fokus (gefördert durch die Sächsische Aufbaubank) umgesetzt, das auf den Ergebnissen dieses Projekts aufbaut.