

## Anwendungen

Johannes Masino, Guillaume Lvasseur, Michael Frey, Frank Gauterin, Ralf Mikut und Markus Reischl\*

# Charakterisierung der Fahrbahnbeschaffenheit durch Data Mining von gemessenen kinematischen Fahrzeuggrößen

Characterization of road states using data mining based on kinematic vehicle sensors

<https://doi.org/10.1515/auto-2017-0061>

Eingang 8. Juni 2017; angenommen 22. Oktober 2017

**Zusammenfassung:** Die Arbeit beschreibt eine Untersuchung von Data-Mining-Ansätzen zur Klassifikation der Fahrbahnbeschaffenheit mittels einfacher Beschleunigungssensoren und Gyroskope. Ziel ist sowohl die Klassifikation des Fahrbahnmaterials als auch das Erkennen von Unregelmäßigkeiten wie z. B. Schlaglöcher oder Bahnübergänge. Aus den Sensorsignalen werden frequenzbasierte Merkmale extrahiert, automatisch bewertet und diskutiert. Die besten Merkmale kommen beim Entwurf verschiedener Klassifikationsverfahren zum Einsatz. Die verwendeten Verfahren werden schließlich in einer MATLAB-Toolbox implementiert, die Klassifikationsergebnisse auf Karten ausgibt, so dass eine manuelle Prüfung der Ergebnisse möglich wird. Anhand eines umfangreichen exemplarischen Datensatzes werden die Ergebnisse diskutiert.

**Schlüsselwörter:** Fallstudie, Inertialsensoren, Prädiktion, Fahrbahn, Schlagloch.

**Abstract:** This paper examines data mining approaches to classify the state of road surfaces by simple sensors

---

\***Korrespondenzautor:** Markus Reischl, Institut für Angewandte Informatik, Karlsruher Institut für Technologie, Hermann von Helmholtz Platz 1, 76344 Eggenstein, E-Mail: markus.reischl@kit.edu

**Johannes Masino, Michael Frey, Frank Gauterin:** Institut für Fahrzeugsystemtechnik, Karlsruher Institut für Technologie, Karlsruhe

**Guillaume Lvasseur:** IRIDIA-Labor, Ecole Polytechnique, Université Libre de Bruxelles, Brüssel, Belgien

**Ralf Mikut:** Institut für Angewandte Informatik, Karlsruher Institut für Technologie, Karlsruhe

such as acceleration sensors and gyroscopes. The work aims for classification of road material and the recognition of irregularities such as potholes or railroad crossings. The sensor information therefore is transformed into frequency-based features, which are automatically rated and discussed. The best features are used to design classification routines. All routines are finally implemented into an open-source MATLAB-toolbox visualizing classifier results upon road maps, enabling the user to manually validate the results. All results are discussed using an extensive exemplary data-set.

**Keywords:** Case study, inertial sensor, prediction, road surface, pothole.

## 1 Motivation

Schlechte Zustände der Straßeninfrastruktur waren 2006 verantwortlich für 50% der tödlichen Unfälle in Frankreich [3], und in Deutschland gab es 2016 vier Unfälle, die nachweislich ausschließlich durch Schäden an der Fahrbahnoberfläche verursacht wurden [1].

Deshalb ist es das Ziel der Bauämter, den Straßenzustand zu überwachen, um eine Verbesserung der Straßenverkehrssicherheit durch die Detektion und Ausbesserung der Straßenschäden zu erreichen. Die Ergebnisse der Detektionen erlauben dann eine gezielte und kostenoptimierte Wartung der Straßen. Von den ausgewerteten Straßenabschnitten können zudem Anbieter von Navigationssystemen profitieren, indem beispielsweise Straßen in schlechtem Zustand in der Routenplanung gemieden werden [13] oder auch Automobilhersteller, um adaptive PKW-Aufhängungen zu steuern und Warnmeldungen in Echtzeit anzuzeigen [19].

Eine datenbasierte Straßenzustandsschätzung hat im Vergleich zu einer physikalischen Modellierung den Vorteil, dass sie keine umfangreiche Systemcharakterisierung (Fahrzeug, Straße, Sensor, Umgebung etc.) erfordert. Weiterhin benötigt die Modellierung eines Vollfahrzeugs fünf Beschleunigungssensoren bzw. Gyroskope, um die vertikalen Beschleunigungen der ungefederten Massen sowie die Beschleunigungen und Drehbewegungen des Fahrzeugaufbaus zu messen [6].

Zur Überwachung von Straßenabschnitten kann ein Fahrzeug als mobile Sensorplattform eingesetzt werden, welche sowohl die Fahrzeugdynamik als auch die Umgebung (wie z. B. Fahrbahnzustand) aufzeichnet. Für die Beschreibung des Fahrbahnzustandes kommen vor allem Inertialsensoren zur Aufzeichnung von Drehgeschwindigkeiten und -beschleunigungen als auch Kameras in Frage. Diese Art von Sensoren ist in modernen Fahrzeugen mit aktivem Fahrwerk oder neuartigen Lichtsystemen meist bereits eingebaut. Der Inertialsensor ist teilweise in der Serienausstattung von neuen Fahrzeugen zur Fusion mit GPS für eine genauere Positionsbestimmung integriert, wie z. B. bei dem neuen Audi A7 [17]. Somit kann die erarbeitete Auswertemethodik nicht nur auf Fahrzeuge, welche mit dem hier vorgestellten Messsystem ausgestattet wurden, sondern auch auf Serienfahrzeuge mit entsprechender Sensorik angewandt werden. Bisherige Studien konnten zeigen, dass mit diesen Sensoren Straßenmerkmale ableitbar sind, wie zum Beispiel Schlaglöcher oder Flickstellen auf Asphaltstraßen [5, 7, 15].

Der Vorteil des Inertialsensors besteht darin, dass er günstig und in vielen Fahrzeugen ohne spezielle Sonderausstattung verbaut ist. Schon Informationen über kleinere Unebenheiten, welche das Fahrzeug in Schwingung versetzen, sind in den Daten des Inertialsensors enthalten. Jedoch kann mit Inertialsensoren nur der direkt überfahrene Fahrbahnbereich ausgewertet werden.

Im Gegensatz dazu zeichnen Kameras den gesamten Fahrbahnbereich vor dem Fahrzeug inklusive je einer Nebenspur auf. Kameras werden hingegen nur in hochklassigen Fahrzeugen mit speziellen Ausstattungspaketen verbaut. Weiterhin haben aktuelle Serien-Kameras in Fahrzeugen eine begrenzte Genauigkeit und können zum Beispiel nur Schlaglöcher mit einer Tiefe ab ca. 3 cm erkennen.

Bisher wird der Fahrbahnzustand vor allem auf Autobahnen mit kostenintensiven und komplexen Messfahrzeugen automatisch oder im städtischen und ländlichen Bereich manuell erfasst [16]. Nachteil dieser Methoden ist der hohe Aufwand sowie die Dauer bis zur Aktualisierung der Bewertung der Straßennetzqualität aufgrund der manuellen Auswertung. Insbesondere sicherheitsrelevan-

te Schäden können zu spät entdeckt werden und kritische Folgen nach sich ziehen, wie z. B. Verkehrsunfälle oder die kostenintensive, komplette Erneuerung der Straße.

Für die Straßenerhaltung findet in einigen Ländern die Ermittlung der stochastischen Fahrbahnproftiefe bzw. des International Roughness Index (IRI), beschrieben in [23], statt. Letzterer wird jedoch oft nur für 100 m-Intervalle berechnet, weshalb einzelne Hindernisse, wie z. B. Schlaglöcher, nicht erfasst werden. Deshalb werden in Ländern mit einer systematischen Straßenerhaltung nicht nur der IRI, sondern vor allem Einzelhindernisse erfasst, was auch das Ziel dieser Studie ist.

Es existieren Ansätze für eine automatisierte Fahrbahnzustandserfassung mit Inertialsensoren, z. B. [2, 5, 14, 20]. Diese konzentrieren sich jeweils jedoch nur auf einzelne Straßenmerkmale (z. B. Schlaglöcher), weisen keinen repräsentativen Datensatz auf oder haben Daten unter eingeschränkten Bedingungen, z. B. begrenzte Geschwindigkeitsbereiche oder nur auf bestimmten Strecken, erfasst. Des Weiteren wird in der Validierung oft nur überprüft, ob es sich bei detektierten Straßenschäden tatsächlich um Schäden handelt (falsch positiv), aber nicht, ob Straßenschäden nicht erkannt werden konnten (falsch negativ).

Zudem ist für die Straßenbauämter die Kenntnis des Materials (Straßenbelag) von großer Bedeutung, da Reparaturmaßnahmen auf verschiedenen Belägen unterschiedlich ausfallen und andere Schadensfälle auftreten können [21]. Weiterhin muss zwischen sicherheitsrelevanten Schäden, welche innerhalb von 24 h repariert werden müssen, und nicht sicherheitsrelevanten Schäden, deren Reparaturmaßnahmen geplant und aufgeschoben werden können, differenziert werden.

Um die grundsätzliche Machbarkeit der automatisierten Erfassung von Straßenbelag und Straßenschäden zu bewerten, ist es das Ziel dieser Arbeit,

- eine Verarbeitungskette zur Auswertung von Fahrbahndaten auf der Basis von Inertialsensoren zu konzipieren,
- die automatisierte Aufzeichnung eines geeigneten Datensatzes durchzuführen,
- eine Methode zur Schätzung von Straßenbelägen und -schäden zu entwickeln und zu bewerten sowie
- die entwickelten Algorithmen in eine grafische Benutzeroberfläche einzubinden, so dass Datensätze mit alternativen Parametrierungen auch von fachfremden Personen ausgewertet werden können.

Abschnitt 2 stellt hierzu die methodische Vorgehensweise vor, Abschnitt 3 zeigt die daraus abgeleitete Implementierung und Abschnitt 4 erläutert die Ergebnisse anhand ei-

nes ersten Datensatzes. In Abschnitt 5 wird das Resultat bzgl. Einsetzbarkeit und offener Probleme diskutiert.

## 2 Methoden

### 2.1 Konzeption

Abbildung 1 gibt einen Überblick über das Vorgehen zur Bewertung des Straßenzustandes. In einem ersten Schritt ist der Straßenzustand durch geeignete Sensoren zu erfassen. Hierzu können akustische Sensoren, wie z. B. in [9], Beschleunigungs- und Drehgeschwindigkeitssensoren, Kameraaufnahmen u. ä. verwendet werden. Als Resultat werden mehrere synchronisierte Zeitreihen erhalten.

Um einen repräsentativen Referenzdatensatz zu erhalten, sind Sensordaten so aufzuzeichnen, dass möglichst viele Ausprägungen variierender Randbedingungen (z. B. Variationen in Außentemperatur, Fahrer, Geschwindigkeit etc.) enthalten sind. Jeder Zeitpunkt / Straßenabschnitt ist zeitgleich oder im Nachhinein mit einer Ausgangsgröße (z. B. Art des Straßenbelags) zu belegen. Auf diese Weise entsteht ein Datensatz mit korrekten Zuordnungen von Sensordaten zu Ausgangsgrößen (engl. Ground Truth). Mittels Data-Mining können Modelle entworfen werden (offline), die schließlich eine retrospektive Aus-

wertung (offline) oder eine Klassifikation im fahrenden Betrieb (online) erlauben. Die Ergebnisse der Klassifikationsmodelle müssen schließlich auf der Basis von Kartenmaterialien visualisiert und bewertet werden.

Um die für die Straßenbauämter wichtigen Informationen Straßenbelag und Ereignis/Schaden zu schätzen, sind zwei separate Klassifikationsroutinen zu entwickeln.

### 2.2 Datenerfassung

Die Daten der im Fahrzeug verbauten Sensoren (z. B. GPS- und Inertialsensor) sind auf dem CAN-Bus kodiert hinterlegt und ohne die Kommunikationsmatrix, welche nur dem Steuergeräteentwickler und dem Automobilhersteller zur Verfügung steht, nicht lesbar. Daher wird in dieser Arbeit ein kostengünstiges Messsystem vorgeschlagen, welches dem im Fahrzeug verbauten Inertialsensor gleicht. Ziel ist ein einfaches Aufnehmen und Auslesen der Daten, erfasst werden Position und Dynamik des Fahrzeugs, insbesondere die Vertikaldynamik aufgrund von Unebenheiten [8]. Weiterhin können die Daten bereits während der Aufnahme mit Ausgangsgrößen versehen werden.

Das Messsystem (Abbildung 2, links) besteht aus einem GPS-Empfänger (Adafruit ultimate GPS Hat) und einem MEMS Inertialsensor (Sense Hat), welcher die Beschleunigungen und Drehraten des Fahrzeugs in alle drei Achsen erfasst. Die Daten der Sensoren werden mit einem Raspberry Pi erfasst und fusioniert in einer Tabelle abgespeichert.

Der GPS-Empfänger hat eine Abtastrate von 10 Hz, eine Positionsaufösung von 3 m und eine Geschwindigkeitsaufösung von 0,1 m/s. Da es sich bei dem Inertialsensor um einen kostengünstigen MEMS Sensor handelt, ist die Abtastrate nicht konstant, was in der Datenverarbeitung mit einem Filter kompensiert werden muss. Die Abtastrate liegt bei ca. 220 Hz und die Genauigkeit des Beschleunigungssensors ist 0,05 m/s<sup>2</sup> und des Gyroskops

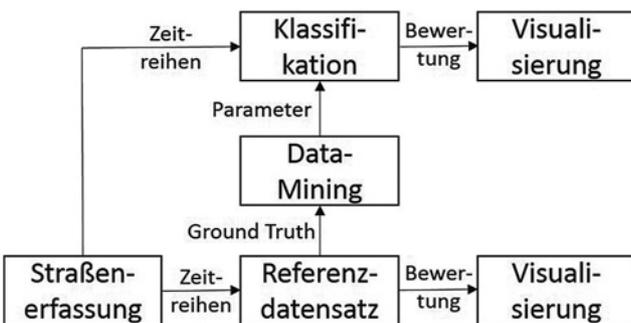


Abbildung 1: Methodenübersicht.



timestamp	sensor_id	x-accel	y-accel	z-accel	x-gyro	y-gyro	z-gyro	gps_time/lat	lon	speed	button1	button2	
1458246893.1088	sensor_L5H	0.001333	-0.09879	-0.84705	0.009172	0.021809	-0.00871	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1178	sensor_L5H	-0.00839	0.03145	-0.93338	-0.0035	-0.01225	-0.0081	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1228	sensor_L5H	0.029635	0.01825	-0.92816	-0.00488	-0.00767	-0.00581	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1274	sensor_L5H	0.006848	-0.06378	-1.01256	-0.01725	0.008064	-0.04109	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1322	sensor_L5H	-0.02305	-0.07441	-1.03004	-0.0171	-0.00507	-0.01207	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1368	sensor_L5H	-0.02335	-0.04588	-1.03156	-0.02366	-0.02019	-0.00657	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1419	sensor_L5H	-0.01243	-0.0394	-0.93813	-0.02763	-0.01194	-0.00596	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1466	sensor_L5H	-0.00404	-0.07771	-0.89333	-0.01633	0.005316	-0.01054	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1513	sensor_L5H	-0.00513	-0.00649	-0.89872	-0.02122	-0.00537	-0.00413	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1568	sensor_L5H	-0.02178	-0.04588	-0.93432	-0.01816	-0.01255	-0.00871	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1617	sensor_L5H	-0.04447	-0.1517	-0.845	-0.01496	-0.01332	-0.0084	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1669	sensor_L5H	0.014121	0.00803	-0.84981	0.001384	-0.00919	-0.00504	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1716	sensor_L5H	-0.02269	-0.05549	-0.89796	0.006118	0.006079	-0.00474	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1761	sensor_L5H	-0.01026	0.021778	-0.87954	0.017267	-0.01164	-0.00367	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1811	sensor_L5H	-0.01876	-0.01333	-0.95784	0.013449	-0.00583	-0.00642	2016-06-2	48.93948	8.363197	23.886	1	0
1458246893.1860	sensor_L5H	-0.03336	-0.03279	-1.0081	0.012227	-0.01041	-0.00856	2016-06-2	48.93948	8.363197	23.886	1	0

Abbildung 2: Links: Verwendete Messeinheit bestehend aus Raspberry Pi, Sense Hat und Adafruit ultimate GPS Hat, rechts: Exemplarische Darstellung der aufgezeichneten Daten im CSV-Format.

**Tabelle 1:** Klassen von Materialien und Ereignisse und ihre Kodierung mit natürlichen Zahlen ( $m$  und  $e$ ).

$m$ – Material	$e$ – Ereignis
0 – Asphalt	0 – unbekannt
1 – Beton	1 – gut
2 – Kopfsteinpflaster	2 – Schlagloch
	3 – Bremsschwelle
	4 – sonstige Unebenheiten

0,003°/s. Ohne Zwischenübertragung können mit einer 32 GB Speicherkarte Messdaten bis zu 1.000 h aufgezeichnet werden.

Für das Versehen der Daten mit Ausgangsgrößen gibt es in der Literatur unterschiedliche Ansätze. Beispielsweise kann ein Mikrofon die (Straßen-)Schadensmeldung des Beifahrers aufzeichnen [20]. Diese Methode weist jedoch mehrere Mängel auf. Unter anderem werden die Ausgangsgrößen stark verzögert zum tatsächlichen Straßenschaden aufgezeichnet und die Tonspur war nicht synchron mit den Sensordaten. Des Weiteren benutzt [5] ‚loosely labeled‘ Trainingsdaten, bei denen für große Straßensegmente nur die Anzahl der Klassen aufgenommen wurde, aber nicht die exakte Position.

Das entwickelte Messsystem für diese Studie wurde mit zwei Tastern versehen, durch gedrückten Taster werden Schadensklasse oder Straßenbelagswechsel annotiert<sup>1</sup>. Dabei werden für jede Messfahrt jeweils Daten mit einem bestimmten Material (z. B. wenn Asphalt 1, sonst 0) und einem Ereignis (z. B. wenn Schlagloch 1, sonst 0) aufgenommen. Nach den Messfahrten wurde die binäre Kodierung der Daten der jeweiligen Dateien in die Kodierung entsprechend Tabelle 1 transformiert.

Insgesamt werden die Unixzeit  $t$ , ID für den Sensor, Geschwindigkeit  $v$ , Position und Zeitstempel des GPS  $lat$ ,  $lon$ ,  $t_{GPS}$ , Beschleunigungen  $a$  und Drehraten  $g$  in alle drei Achsen, sowie die zwei Label für Ereignis  $e$  und Material  $m$  aufgezeichnet und in einer csv-Tabelle auf dem Messsystem gespeichert (Abbildung 2).

Das Messsystem ist in der Nähe des statischen Schwerpunktes eines BMW 116d angebracht, in der Konsole zwischen Fahrer und Beifahrersitz. Die Orientierung der Sensorachsen stimmt mit den Fahrzeugachsen nach ISO 8855:2011 überein. Um eine Generalisierung der vorgestellten Methode zu gewährleisten, werden Messdaten auf zufällig gewählten Straßen im Raum Karlsruhe auf-

gezeichnet. Dabei werden die Geschwindigkeit, die Fahrbahnbeschaffenheit und die Umweltbedingungen (z. B. Messfahrten bei gutem und regnerischem Wetter) stark variiert. Insgesamt werden Referenzdaten auf über 200 km Strecke in einem Zeitraum von 3 Monaten aufgezeichnet. Die Daten wurden an 8 Tagen (3mal ganztägig) von drei verschiedenen Fahrern aufgezeichnet. Die Erfassung von Referenzdaten ist ein langwieriger Prozess, da die Überfahrt der Materialien und Ereignisse unter Variation der Umweltbedingungen und Geschwindigkeiten erfolgen muss. Insbesondere müssen Einzelereignisse, wie z. B. Schlaglöcher, mit unterschiedlichen Ausprägungen im Straßennetz gefunden und mit variierenden Anfahrwinkeln und Fahrzeugspuren mehrfach überfahren werden.

Die aufgrund unterschiedlicher Abtastraten fehlenden Werte der GPS-Daten werden durch eine lineare Interpolation rekonstruiert. Da die Messreihen zudem nicht mit konstanter Abtastrate aufgezeichnet werden, ist ein Resampling notwendig. Dieses überführt die Daten vom Zeitbereich ( $s^{-1}$ ) in den Ortsbereich (in  $m^{-1}$ ). In [18, 22] wurde gezeigt, dass die Antwort vom Fahrzeug auf die Anregung der Straße von der Geschwindigkeit abhängig ist und dass die Darstellung im Ortsbereich diesen Effekt vermindert. Alle Zeitreihen werden mit einer (Orts-)Frequenz von  $100 m^{-1}$  resampelt. Die gefahrene Strecke wird aus dem Zeitstempel und der Geschwindigkeit mithilfe des impliziten Euler-Verfahrens berechnet<sup>2</sup>.

Die Klassen der Beläge  $m$  und der Ereignisse  $e$  werden mit natürlichen Zahlen kodiert (Tabelle 1). Hierbei repräsentiert die Klasse sonstige Unebenheiten sämtliche bauliche Hindernisse, wie z. B. Bahnübergänge, und allgemeine Unebenheiten. Allgemeine Unebenheiten sind nicht sicherheitsrelevant und beschreiben kleinere Ausbrüche sowie Reparaturstellen. Eine Bremsschwelle wurde als quer zur Fahrtrichtung angeordnete bauliche Erhebung definiert und ein Schlagloch als Ausbruch mit einer Tiefe von mindestens 2 cm. Letzteres Ereignis ist sicherheitsrelevant und sollte innerhalb von maximal 24 h repariert werden. Für jeden Abtastpunkt  $k$  des Referenzdatensatzes werden zwei Label für das Material  $m[k]$  und das Ereignis  $e[k]$  erfasst.

## 2.3 Signalverarbeitung

Um aus den aufgezeichneten Sensordaten eine Entscheidung über Straßenbelag und Ereignis/Schaden abzuleiten, sind die Zeitreihen vorab in einen Merkmalsraum zu

<sup>1</sup> In der Folge der Arbeit werden die Beläge „Material“ und die Schäden „Ereignis“ genannt.

<sup>2</sup> Eine Berechnung über GPS ist ebenfalls möglich, aber ungenauer.

überführen. Die Merkmalsextraktion berechnet repräsentative und nützliche Einzelmerkmale aus den kompletten oder partiellen Messreihen. Ohne Kenntnis des physikalischen Modells der Auswirkungen von Asphaltänderungen oder Straßenschäden auf den Sensor bietet es sich an, einen großen Satz an Merkmalen zu berechnen und anhand von Daten mit zugehörigen Ausgangsgrößen (Ground Truth) ihre Eignung bezüglich des Klassifikationsproblems zu untersuchen. Wichtig ist hierbei eine effiziente Merkmalsberechnung, um die Möglichkeit der Berechnung auf mobilen Geräten (z. B. Mikrocontroller) zu erhalten.

### 2.3.1 Generierung neuer Zeitreihen

Zur Beschreibung des Straßenzustandes sind die Beschleunigung in der Vertikalen ( $a_z$ ) und die Drehgeschwindigkeiten um Längs- und Querrichtung ( $g_x$  und  $g_y$ ) besonders wichtig [5]. Es werden einerseits einfache zeitliche Differenzen dieser drei Messreihen gebildet, andererseits bandpassgefilterte Signale zur Isolierung von Frequenzbändern im Signal.

Das Differenzsignal  $dx$  einer diskreten Variable  $x$  für eine Zeitreihe von  $N$  Punkten wird folgendermaßen berechnet:

$$\forall k = 2 \dots N : dx[k] = x[k] - x[k-1], \quad dx[1] = 0.$$

Als Bandpassfilter werden diskrete Butterworthfilter 2. Ordnung berechnet<sup>3</sup> gemäß

$$y[k] = \sum_{j=0}^{n_b} b_j x[k-j] - \sum_{i=1}^{n_a} a_i y[k-i].$$

Anhand der Spektrogramme der Querdrehgeschwindigkeit  $g_y$  für die drei Materialien werden folgende acht Frequenzbereiche<sup>4</sup> heuristisch als interessant bestimmt und zur Berechnung der Bandpassfilter herangezogen:

$$\begin{aligned} & [0.01, 0.1] \quad [0.1, 0.5] \quad [0.5, 1] \quad [1, 3] \quad [3, 5] \quad [5, 7] \\ & [7, 10] \quad [10, 15] \quad [15, 20] \quad [20, 30]. \end{aligned}$$

Insgesamt werden so 33 zusätzliche Zeitreihen aus den drei wichtigen Messreihen erzeugt (Differenzsignal

<sup>3</sup> Für das Butterworthfilter 2. Ordnung gilt:  $n_a = n_b = 5$ . Die Koeffizienten  $a_i$  und  $b_j$  werden mithilfe der Matlab-Funktion `butter` bestimmt [10].

<sup>4</sup> Wegen der Darstellung im Ortsbereich werden die Frequenzen nicht in Herz [Hz], sondern in „pro Meter“ [ $\text{m}^{-1}$ ] dargestellt.

und 10 bandpassgefilterte Signale für 3 Zeitreihen). Die zusätzlichen Zeitreihen aus den Bandpassfiltern werden (am Beispiel der Vertikalbeschleunigung<sup>5</sup>) folgendermaßen notiert:  $az0000$  für den Frequenzbereich  $[0.01, 0.1]$ ,  $az0001$  für den Bereich  $[0.1, 0.5]$ ,  $az0103$  für den Bereich  $[1, 3]$ , usw. Die originalen Zeitreihen werden für die weitere Analyse nicht weiter betrachtet.

### 2.3.2 Merkmalsberechnung

Zum Entwurf eines Klassifikators werden aus den insgesamt 34 Zeitreihen (33 abgeleitete Zeitreihen, eine Geschwindigkeitszeitreihe) Merkmale in sich überlappenden Fenstern berechnet. Ein Fenster  $U_i$  bezeichnet alle Indices  $[n_i - \frac{L}{2}, n_i + \frac{L}{2} - 1]$  mit dem Laufindex  $n$ , dem Fensterindex  $i$  und der Fensterlänge  $L$ . Die Fensterüberlappung  $r$  entspricht dem Anteil an Werten aus dem Fenster  $U_i$ , die im vorhergehenden Fenster  $U_{i-1}$  enthalten sind, d. h.  $n_{i+1} = n_i + L(1 - r)$ .

Die Fensterlängen werden heuristisch gewählt – 20 m für die Materialien und 5 m für die Ereignisse<sup>6</sup>. Es wird eine Fensterüberlappung von  $r = 20\%$  ausgewählt.

Für die Geschwindigkeit wird der Mittelwert  $\bar{v}[i]$  berechnet.

Für die 33 abgeleiteten Zeitreihen werden vier Einzelmerkmale in den Fenstern berechnet: Mittelwert  $\bar{x}[i]$ , Standardabweichung  $x_S[i]$ , Maximum des Betrags  $x_M[i]$  und die massenspezifische Energie  $x_I[i]$  mit<sup>7</sup>

$$x_I[i] = \frac{1}{L} \sum_{k \in U_i} |x[k] - \bar{x}[i]|.$$

Es ergeben sich somit  $4 \cdot 33 + 1 = 133$  Einzelmerkmale pro Fenster sowie die Position des Fensters als GPS-Koordinaten. Alle Fenster mit einer mittleren Geschwindigkeit kleiner als 2 m/s werden verworfen, da der

<sup>5</sup> Die 18 zusätzlichen Zeitreihen aus  $g_x$  und  $g_y$  werden analog berechnet und notiert.

<sup>6</sup> Die Fensterlänge für die Ereignisse ist kleiner, da Straßenschäden eine deutlich kleinere Ausdehnung haben als Beläge. Die Fensterberechnung dient lediglich dem Nachweis der Machbarkeit, aktuell finden die Arbeiten statt, um auf die Fensterberechnung zu verzichten und stattdessen geeignete Filterroutinen zu verwenden.

<sup>7</sup> Um eine onlinefähige Implementierung zu erhalten, wurde die massenspezifische Energie eines Frequenzbandes durch ein IIR-Filter ( $a = 0.999$ ) abgeschätzt gemäß

$$x_I[k] = \begin{cases} |x[k] - \bar{x}[i]| & k = n_i - \frac{L}{2} \\ a x_I[k-1] + (1-a)|x[k] - \bar{x}[i]| & \text{sonst} \end{cases}$$

**Tabelle 2:** Gewichte der 5 Klassen von Ereignissen für die Methode der gewichteten Häufigkeiten.

Ereignis $e$	Gewicht $\omega_e$
2 – Schlagloch	1,000
4 – sonstige Unebenheit	0,500
3 – Bremsschwelle	0,333
1 – gut	0,250
0 – unbekannt	0,200

Straßenzustand bei sehr kleinen Geschwindigkeiten mit einem Inertialsensor nicht erfassbar ist. Die Menge der Datenpunkte aus der Merkmalsberechnung bilden zwei Matrizen der Eingangsgrößen:  $\mathbf{X}_m$  für die Materialien und  $\mathbf{X}_e$  für die Ereignisse.  $\mathbf{X}_m$  verfügt über 6525 Datenpunkte,  $\mathbf{X}_e$  über 23 627.

Des Weiteren muss jedem Fenster ein Wert für die Ausgangsgrößen der Materialien  $m$  und der Ereignisse  $e$  zugeordnet werden. In den meisten Fällen ist dieser Wert eindeutig, da ein Ereignis oder Material das komplette Fenster ausfüllt. Ist dies nicht der Fall, wenn sich z. B. in einem 5 m Fenster ein Schlagloch mit 1 m Länge befindet und sonst das Fenster als ‚gut‘ gekennzeichnet ist, werden den Ereignissen Gewichte gemäß ihrer Wichtigkeit  $\omega_e$  zugeordnet (Tabelle 2). Im genannten Beispiel soll das Fenster beispielsweise als ‚Schlagloch‘ und nicht als ‚gut‘ gelabelt werden. Die Anwendung der Gewichte findet nur beim Labeln der Fenster im Trainingsprozess statt. Die Klasse des Materials  $\tilde{m}[i]$  wird nach der Häufigkeit im Fensterintervall  $U_i$  bestimmt

$$\tilde{m}[i] = \operatorname{argmax}_{k \in U_i} m[k].$$

So kann vermieden werden, dass ein Ereignis, z. B. ein Schlagloch, bei mehrheitlich gutem Belag in einem Fenster übersehen wird. Die Ereignisklasse des Fensters  $\tilde{e}[i]$  wird mithilfe der gewichteten Häufigkeiten bestimmt:

$$\tilde{e}[i] = \operatorname{argmax}_{\xi \in \{0,1,2,3,4\}} (\omega_e(\xi) \cdot \operatorname{card}\{k | e[k] = \xi \forall k \in U_i\})$$

Analog zu den Einzelmerkmalen werden die Ausgangsgrößen in Vektoren zusammengefasst,  $\mathbf{y}_m$  mit 6525 und  $\mathbf{y}_e$  mit 23 627 Elementen.

Aus den GPS-Zeitreihen Breite  $lat$  und Länge  $lon$  werden Mediane in jedem Fenster für die spätere Visualisierung verwendet.

### 2.3.3 Klassifikation

Anhand der extrahierten Einzelmerkmale und den entsprechenden Ausgangsgrößen werden zwei Klassifikatoren für Material und Ereignis entworfen. Für Entwurf und Anwendung der Klassifikation wird eine Kombination aus Merkmalsauswahl, Merkmalsaggregation und Klassifikator gewählt.

Für die beiden Klassifikationen werden jeweils die 10 besten Einzelmerkmale mittels des MANOVA-Verfahrens bestimmt. Die ausgewählten Einzelmerkmale werden dann mit der linearen Diskriminanzanalyse (DA) zu zwei Merkmalen aggregiert, um den Rechenaufwand zu minimieren und Visualisierungen des Merkmalsraums zu ermöglichen (Abbildung 4, oben). Als Klassifikator kommt ein Bayes-Klassifikator mit klassenspezifischen Kovarianzmatrizen zum Einsatz<sup>8</sup>. Die Validierung wird mithilfe des Bootstrap-Verfahrens mit 15 Versuchen durchgeführt.

## 3 Implementierung

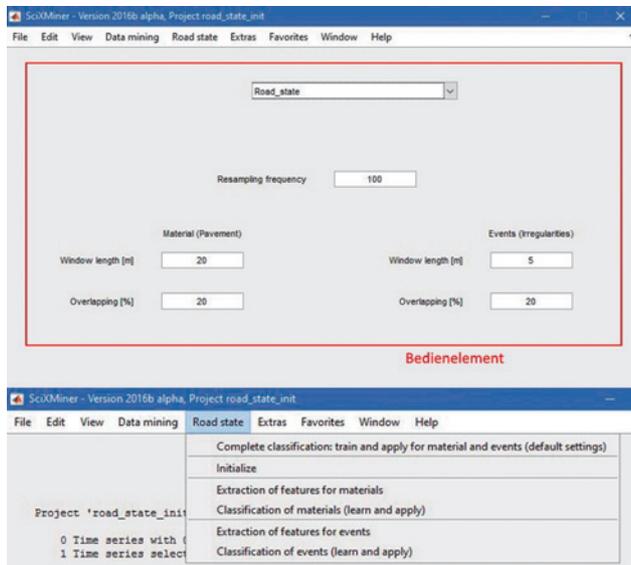
Die dargestellten Methoden wurden zur Erleichterung der Bedienung für fachfremde Personen in eine grafische Benutzerschnittstelle „Road state“ implementiert. Sie basiert auf MATLAB und ist in der frei verfügbaren Toolbox SciX-Miner [11]<sup>9</sup> (vormals Gait-CAD [12]) integriert. Damit können auch die anderen Erweiterungspakete von SciX-Miner verwendet werden, z. B. zur Überprüfung der Datenqualität [4]. Das Bedienelement und das Menü von „Road state“ sind in Abbildung 3 dargestellt. „Road state“ ermöglicht

- eine Bedienung über eine Benutzeroberfläche in SciX-Miner,
- die automatische Datenvorverarbeitung und die Klassifikation der Materialien und Ereignisse,
- die Verwendung neuer Datensätze als Lern- (Referenzdatensatz) oder Testdaten,
- die Definition der Parameter für Merkmalsextraktion und Klassifikation (z. B. Fensterlängen, Überlappungen und Resampling-Frequenz) und
- die Visualisierung der Ergebnisse mithilfe von Grafiken und Karten anzeigen.

Im Dialogfeld von „Road state“ können die Resampling-Frequenz, die Fensterlängen und die Überlappungen für

<sup>8</sup> Verfahren, die höhere Merkmalsdimensionen oder andere Klassifikatoren verwenden, liefern bessere Ergebnisse, lassen sich aber nur schlecht visualisieren.

<sup>9</sup> Download: <https://sourceforge.net/projects/scixminer>



**Abbildung 3:** Grafische Benutzerschnittstelle des Programmpakets „Road state“ in SciXMiner: Oben: Dialogfeld zur Einstellung der wichtigsten Parameter, unten: Menüoptionen zum automatisierten Ausführen und Anwenden der Data-Mining-Verfahren.

die Merkmalsextraktionen der Materialien und der Ereignisse eingestellt werden. Die Resampling-Frequenz darf Werte zwischen 1 und  $1000 \text{ m}^{-1}$  annehmen, die Fensterlängen können zwischen 1 und 100 m eingestellt werden, die Überlappungen zwischen 0 und 99%.

Die Merkmalsextraktion ist mit den benutzerdefinierten Parametern möglich. Dieser Modus erlaubt auch die Merkmalsextraktion und die Klassifikation von den Materialien oder den Ereignissen unabhängig voneinander. Für beide Modi wird der Klassifikator mit den annotierten Daten entworfen und auf alle Daten, inklusive den nichtannotierten, angewendet.

Zur Visualisierung werden in jedem Fenster die GPS-Koordinaten zusammengefasst und auf einer Karte in Kombination mit den Ausgangsgrößen dargestellt (vgl. Abbildung 4). Solche grafischen Informationen sind hilfreich, um die Ergebnisse der Klassifikation kritisch zu hinterfragen. Im vorliegenden Fall werden farbige Linien für die Materialien und farbige Markierungen für die Ereignisse gewählt.

## 4 Ergebnisse

### 4.1 Belagsklassifikation

Bei der Klassifikation der Straßenbeläge liefert die Bootstrap-Validierung durchschnittlich 9,3% Fehlklassifikationen. Die Darstellung des aggregierten Merk-

malsraums und der Klassifikation zeigt Abbildung 4, links oben. Die große Mehrheit der Fehlklassifikationen sind Asphalt-Datenpunkte, die als Beton klassifiziert werden. Ein Blick auf die Merkmale und die kartographische Darstellung der Klassifikation von Lerndaten und unbekanntem Daten (Abbildung 4, links unten) zeigt, dass unter diesen Fehlklassifikationen Datenpunkte mit großen Geschwindigkeiten oft als Beton klassifiziert werden. Zum Beispiel werden Beton-Datenpunkte auf einer Landstraße im Bereich 4 angezeigt, obwohl auf dieser Straße Asphalt verbaut ist.

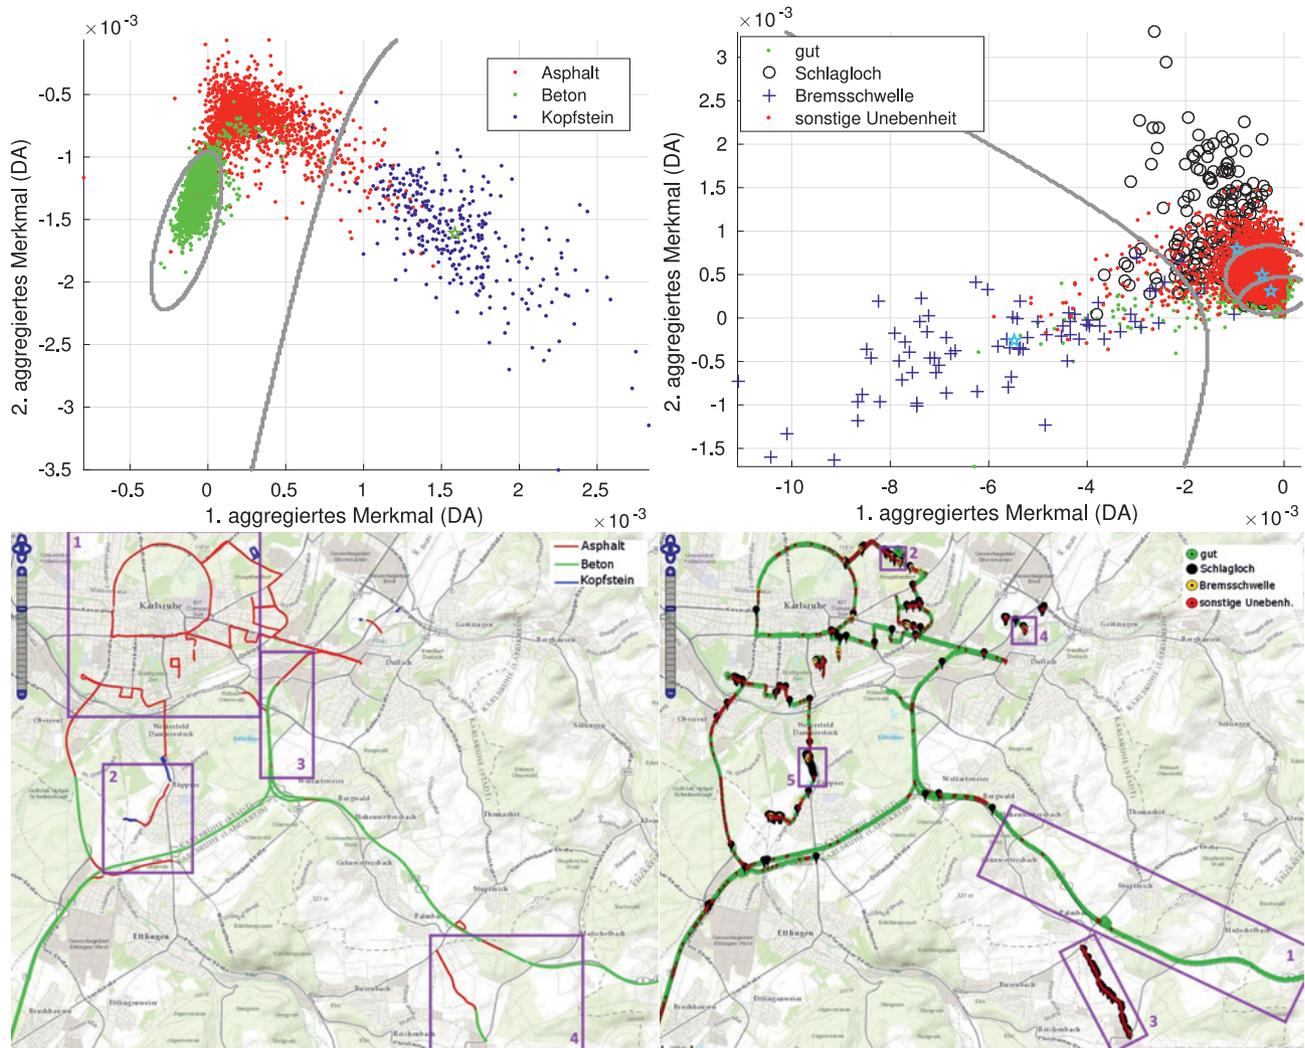
Es hat sich herausgestellt, dass die Anregung des Fahrzeugs auf gutem Asphalt und Beton sehr ähnlich ist. Der Referenzdatensatz besteht für höhere Geschwindigkeiten vor allem aus Daten, welche auf Betonstraßen gesammelt wurden. Somit tendiert der Klassifikator bei hohen Geschwindigkeiten dazu, Asphaltbeläge als Betonbeläge zu präzisieren. Eine robuste Unterscheidung zwischen Asphalt und Beton anhand der Inertialsensordaten ist nur für Betonstraßen mit veralteten Betonfugen möglich, welche das Fahrzeug anregen und somit in den Signalen zu erkennen sind.

In Bereich 3 wird eine Belagsänderung von Asphalt zu Beton vorhergesagt, die so tatsächlich existiert. Im Innenstadtbereich von Karlsruhe (Bereich 1) hat die Klassifikation der Materialien, vor allem Asphalt und Kopfsteinpflaster, eine hohe Genauigkeit. Es werden alle Datenpunkte den richtigen Klassen von Asphalt oder Kopfsteinpflaster zugeordnet. Im Bereich 2 wird ein existierender Belagwechsel von Kopfsteinpflaster zu Asphalt erkannt und der Beton auf der naheliegenden Autobahn richtig klassifiziert. Bereich 2 zeigt eine Fehlklassifikation, bei der ein Bahnübergang als Kopfsteinpflaster erkannt wird.

Eine theoretische Betrachtung der drei besten Einzelmerkmale für die Klassifikation der Materialien nach MANOVA liefert:

1.  $az0103_s$  – die Standardabweichung der zwischen 1 und  $3 \text{ m}^{-1}$  gefilterten Vertikalbeschleunigung,
2.  $gx1015_l$  – die massenspezifische Energie der Längsdrehgeschwindigkeit zwischen 10 und  $15 \text{ m}^{-1}$  und
3.  $\bar{v}$  – der Mittelwert der Geschwindigkeit.

Die Standardabweichung der Vertikalbeschleunigung  $az0103_s$  beschreibt die Vibration des Fahrzeugs in vertikaler Richtung und enthält somit Informationen über das Straßenprofil. Das zweite Merkmal  $gx1015_l$  entspricht der Energie der Schwingungen um die Längsachse, d. h. die Rollbewegung des Fahrzeugs. Der Frequenzbereich von 10 bis  $15 \text{ m}^{-1}$  entspricht der Ausdehnung von Pflastersteinen und ist daher für das Material Kopfsteinpflaster charakteristisch. Das dritte Merkmal  $\bar{v}$  ist nicht direkt



**Abbildung 4:** Links: Oben: Klassifikation der Materialien, Trennlinien des Klassifikators in grau, unten: automatisch generierte Karten des Klassifikationsergebnisses für das Material mit Asphalt (rot), Beton (grün) und Kopfsteinpflaster (blau) mit erfolgreichen Klassifikationen in Bereichen 1 und 2, Belagsänderungen im Bereich 3 und Asphalt wegen der Geschwindigkeit als Beton klassifiziert im Bereich 4. Rechts: Oben: Klassifikation der Ereignisse (ohne Kopfsteinpflaster), unten: Beispiel automatisch generierter Karten des Klassifikationsergebnisses für die Ereignisse mit guten Belägen (grün), Schlaglöchern (schwarz), Bremschwellen (gelb) und sonstigen Unebenheiten (rot). Bereich 1 zeigt richtig klassifizierte Ereignisse, Bereich 2 und 3 falsche Schlaglöcher, Bereich 4 Bahnübergang als Bremschwelle klassifiziert und Bereich 5 Kopfsteinpflaster als Schlagloch klassifiziert.

mit dem Straßenzustand verbunden, sondern mit dem Fahrverhalten. Trotzdem bildet die Geschwindigkeit das Material indirekt ab, da bei hohen Geschwindigkeiten tendenziell Kopfsteinpflaster ausgeschlossen werden können, bei niedrigen Beton.

## 4.2 Ereignisklassifikation

Für die Klassifikation der Ereignisse werden vorab die Datenpunkte ausgeschlossen, die als Kopfsteinpflaster klassifiziert wurden. Das Material Kopfsteinpflaster wird bei

der Ereignisklassifikation zu 84% als Schlagloch klassifiziert (z. B. im Bereich 5 der Abbildung 4, rechts unten). Damit vermindert sich der Lerndatensatz von 23 627 auf 23 147 Datenpunkte<sup>10</sup>.

Bei der Klassifikation der Ereignisse liefert die Bootstrap-Validierung durchschnittlich 28,5% Fehler. Auf der Darstellung des Klassifikationsergebnisses in Abbildung 4, rechts oben, fällt auf, dass im Bereich der guten

<sup>10</sup> Für eine Schadensdetektion auf Kopfsteinpflaster muss ein separater Klassifikator entworfen werden.

Beläge bzw. der sonstigen Unebenheiten Probleme in der Klassifikation bestehen. Eine Erkennung von deutlichen Schlaglöchern, wie von den Straßenbauämtern gefordert, ist jedoch zweifelsohne möglich.

Bremsschwellen, welche als Schlaglöcher klassifiziert wurden, wurden vor allem meist schräg überfahren, so dass das Auto eine Rollbewegung wie beim Durchfahren eines Schlagloches durchgeführt hat.

Die Klassifikation wird kartographisch in Abbildung 4, rechts unten, dargestellt. In den Bereichen 2 und 3 werden Schlaglöcher angezeigt. Bei beiden Abschnitten liegt ein sehr schlechter Straßenzustand vor, jedoch kein Schlagloch<sup>11</sup>. Diese Fehlklassifikationen kommen aus der Überschneidung zwischen den Verteilungen von Schlaglöchern und sonstigen Unebenheiten im Merkmalsraum. Im Bereich 4 wird der Bahnübergang als Bremsschwelle fehlerklassifiziert. In Bereich 1 wird der gute Zustand der Autobahn korrekt klassifiziert.

Für die Klassifikation der Ereignisse sind die 3 besten Einzelmerkmale nach MANOVA:

1.  $gy0001_M$  – das Maximum des Betrags von der Drehgeschwindigkeit um die y-Achse im Frequenzbereich von 0,1 bis 0,5  $m^{-1}$ ,
2.  $gx0000_M$  – das Maximum des Betrags der Drehgeschwindigkeit um die x-Achse zwischen 0,01 und 0,1  $m^{-1}$  und
3.  $dgy_I$  – die massenspezifische Energie vom Differenzsignal der Drehgeschwindigkeit um die y-Achse.

Das Maximum des Betrags bildet die Höchstwerte in einem Fenster ab und repräsentiert somit Unebenheiten und eine hohe Anregung des Fahrzeugs. Die Nickbewegung des Fahrzeugs, welche im Merkmal  $gy0001_M$  enthalten ist, ist für Bremsschwellen charakteristisch. Das zweite Merkmal  $gx0000_M$  ist für Schlaglöcher charakteristisch, da vor allem bei der Überfahrt von Schlaglöchern hohe Werte für die Geschwindigkeit der Rollbewegung des Fahrzeugs auftreten [5]. Das dritte Merkmal  $dgy_I$  entspricht der Energie, die durch inkrementelle Schwingungen des Fahrzeugs um seine Querachse ausgegeben wird. Diese Schwingungen werden durch das konsequente Treffen von Unebenheiten von den Vorder- und Hinterachsen verursacht und können als sonstige Unebenheiten (Bahnübergänge, leichte Straßenschäden, usw.) interpretiert werden.

<sup>11</sup> Je nachdem, wie ein Schlagloch definiert wird, können große Teile dieser Strecke allerdings auch als Schlagloch gelabelt werden

## 5 Zusammenfassung und Ausblick

Die Ergebnisse zeigen, dass das dargestellte System in der Lage ist, Fahrbahnmaterialien sowie Ereignisse zu klassifizieren. Die Merkmale, welche durch MANOVA selektiert wurden, stimmen mit der Theorie der Fahrzeuganregung überein.

Zur Verbesserung der reinen Klassifikationsergebnisse (ohne Visualisierung) können die Parametrierungen optimiert werden. So liefert z.B. eine Support-Vektor-Maschine unter Verwendung von 10 Merkmalen ca. 20% bessere Klassifikationsergebnisse, verschlechtert allerdings die Interpretierbarkeit.

Zur Optimierung der Unterscheidung von Asphalt und Beton kann der Datensatz um langsam befahrenen Beton und schnell befahrenen Asphalt erweitert werden.

Für das weitere Vorgehen ist eine Kategorisierung der Materialien und Ereignisse u. U. sinnvoll. Beispielsweise ist eine Einteilung des Straßenbelags in die Kategorien Kopfsteinpflaster, guter Fahrbahnbelag, schlechter Asphalt und schlechter Beton möglich. Die vorliegende Studie hat gezeigt, dass eine Unterscheidung von gutem Asphalt und gutem Beton oft nicht möglich ist. Da ein guter Fahrbahnbelag, unabhängig von dem verbauten Material, auch für die Instandhaltungsplanung nicht von Bedeutung ist, können diese zwei Klassen in eine neue Klasse zusammengefasst werden. Interessanter sind die Klassen schlechter Asphalt und schlechter Beton.

Ereignisse, welche keine Straßenschäden darstellen, wie zum Beispiel Bahnübergänge, werden teilweise als Schlaglöcher fehlerklassifiziert. Diese Ereignisse könnten jedoch auf einer Karte markiert und von der Klassifikation ausgeschlossen werden, da das Hauptziel ist, Straßenschäden zu detektieren.

Da das System modular aufgebaut ist, können die Anzahl und Art der Sensoren und Sensormodalität variiert werden – bei Anpassung der Merkmalsextraktion sind auch Kameraaufnahmen u. ä. verwertbar.

Die Übertragbarkeit auf andere Fahrzeuge mit abweichendem Fahrwerk und Maßen ist bislang nicht geprüft worden, vermutlich sind die Algorithmen der Parameter an das Fahrzeug angepasst, mit dem der Lerndatensatz aufgezeichnet wurde. Abhilfe leisten kann hier die Fusion von Lerndatensätzen aus mehreren Fahrzeugen und eine entsprechend angepasste Klassifikationsroutine. Hierfür ist anzunehmen, dass sich die Ergebnisse geringfügig verschlechtern.

Insgesamt stellt der Inertialsensor eine sehr gute Möglichkeit dar, kostengünstig und flächendeckend Informationen über den Reifen/Fahrbahn-Kontakt zu sammeln. Mit dem Einsatz der Informationen mehrerer Fahrzeu-

ge kann der Nachteil kompensiert werden, dass einzelne Fahrer sicherheitsrelevante Schäden umfahren, die deshalb nicht von dem Sensor erfasst werden. Weiterhin werden Hindernisse am Straßenrand nicht überfahren und können somit nicht detektiert werden. Eine Fusion aus Kamera- und Inertialsensordaten stellt eine Möglichkeit dar, die mobile Zustandserfassung der Straßenverkehrsinfrastruktur zu optimieren.

Für das von den Straßenbauämtern identifizierte Problem ist der Einsatz des kostengünstigen und recheneffizienten Systems bestehend aus Inertialsensor, Raspberry Pi und einfacher Signalverarbeitung ausreichend und empfehlenswert.

**Danksagung:** Wir danken dem KIT (JM, MF, FG) und der Deutsch-Französischen Hochschule (GL).

## Literatur

1. Statistisches Bundesamt (Destatis): Verkehrsunfälle. Artikelnummer: 2080700161124, 2017.
2. CHEN, K.; TAN, G.; LU, M.; WU, J.: CRSM: a practical crowdsourcing-based road surface monitoring system. *Wireless Networks* 22 (2016) 3, S. 765–779.
3. DE GONNEVILLE, P.; MARTIN, G.: Le mécanisme d'accident. *Setra: Service d'Études techniques des routes et autoroutes, Bagneux* (2006).
4. DONEIT, W.; MIKUT, R.; GRÖLL, L.; PYCHYNSKI, T.; REISCHL, M.: DaMoQ: Eine Open-Source-MATLAB-Toolbox zur Bewertung von Daten- und Modellqualität in Regressionen. *at-Automatisierungstechnik* 65 (2017) 3, S. 207–218.
5. ERIKSSON, J.; GIROD, L.; HULL, B.; NEWTON, R.; MADDEN, S.; BALAKRISHNAN, H.: The Pothole Patrol: Using a Mobile Sensor Network for Road Surface Monitoring. *MobiSys: The ACM Conference on Mobile Systems, Applications, and Services* (2008).
6. ESMAILZADEH, E.; FAHIMI, F.: Optimal adaptive active suspensions for a full car model. *Vehicle System Dynamics* 27 (1997) 2, S. 89–107.
7. KOCH, C.; BRILAKIS, I.: Pothole detection in asphalt pavement images. *Advanced Engineering Informatics* 25 (2011) 3, S. 507–515, Special Section: Engineering informatics in port operations and logistics.
8. MASINO, J.; FREY, M.; GAUTERIN, F.; SHARMA, R.: Development of a highly accurate and low cost measurement device for Field Operational Tests. In: *2016 IEEE International Symposium on Inertial Sensors and Systems*, S. 74–77, 2016.
9. MASINO, J.; PINAY, J.; REISCHL, M.; GAUTERIN, F.: Road Surface Prediction from Acoustical Measurements in the Tire Cavity Using Support Vector Machine. *Applied Acoustics* 125 (2017), S. 41–48.
10. The MathWorks, Inc.: *MATLAB Documentation*. R2016b Aufl., 2016.
11. MIKUT, R.; BARTSCHAT, A.; DONEIT, W.; ÁNGEL GONZÁLEZ ORDIANO, J.; SCHOTT, B.; STEGMAIER, J.; WACZOWICZ, S.; REISCHL, M.: The MATLAB Toolbox SciXMiner: User's Manual and Programmer's Guide. Techn. Ber., arXiv:1704.03298, 2017.
12. MIKUT, R.; BURMEISTER, O.; REISCHL, M.; LOOSE, T.: Die MATLAB-Toolbox Gait-CAD. In: *Proc., 16. Workshop Computational Intelligence*, S. 114–124, Universitätsverlag Karlsruhe, 2006.
13. MOHAN, P.; PADMANABHAN, V. N.; RAMACHANDRAN, R.: Nericell: Rich Monitoring of Road and Traffic Conditions using Mobile Smartphones. *Sensys: The ACM Conference on Embedded Networked Sensor Systems* (2008).
14. PERTTUNEN, M.; MAZHELIS, O.; CONG, F.; KAUPPILA, M.; LEPPÄNEN, T.; KANTOLA, J.; COLLIN, J.; PIRTTIKANGAS, S.; HAVERINEN, J.; RISTANIEMI, T.; ET AL.: Distributed road surface condition monitoring using mobile phones. In: *International Conference on Ubiquitous Intelligence and Computing*, S. 64–78, Springer, 2011.
15. RADOPOULOU, S. C.; BRILAKIS, I.: Patch detection for pavement assessment. *Automation in Construction* 53 (2015), S. 95–104.
16. RADOPOULOU, S. C.; BRILAKIS, I.: Improving Road Asset Condition Monitoring. *Transportation Research Procedia* 14 (2016), S. 3004–3012.
17. SENSOREN AUDI A7; <https://www.mobilegeeks.de/artikel/ein-selbstversuch-pilotiertes-fahren-mit-dem-audi-a7-jack/>, aufgerufen am 02. 11. 2017.
18. SAYERS, M.; GILLESPIE, T.; QUEIROZ, C.: The International Road Roughness Experiment: Establishing Correlation and a Calibration Standard for Measurements. *World Bank Technical Paper* (1986) 45.
19. SCHADE, M.: Der intelligente Löcher-Sucher. *Auto Bild* (2016).
20. SERAJ, F.; DILO, A.; LUARASI, T.; HAVINGA, P.; ATZMUELLER, M.; CHIN, A.; JANSSEN, F.; SCHWEIZER, I.; TRATTNER, C.; OTHERS: RoADS: A Road Pavement Monitoring System for Anomaly Detection Using Smart Phones. *Big data analytics in the social and ubiquitous context* (2016), S. 128–146.
21. TEKIN, I.: *Wirtschaftliche Untersuchungen des aktuellen Stands im Straßenwesen zur Ermittlung der Vorteile und Einsatzgebiete eines Fahrbahn-Monitoring-Systems*. Bachelorarbeit, Karlsruher Institut für Technologie, Institut für Fahrzeugsystemtechnik, Lehrstuhl für Fahrzeugtechnik, 2016.
22. WARD, C. C.; IAGNEMMA, K.: Speed-independent vibration-based terrain classification for passenger vehicles. *Taylor & Francis, Vehicle System Dynamics* 47 (2009) 9.
23. ISO 8608:2016; Mechanical vibration – Road surface profiles – Reporting of measured data.

## Autoreninformationen

**Johannes Masino, M.Sc.**

Institut für Fahrzeugsystemtechnik, Karlsruher Institut für Technologie, Karlsruhe

Johannes Masino ist Mitarbeiter am Institut für Fahrzeugsystemtechnik, Teilinstitut Fahrzeugtechnik am Karlsruher Institut für Technologie (KIT). Forschungsschwerpunkte: Signalverarbeitung, Sensortechnik, Machine Learning, Fahrzeugdynamik.

**Guillaume Levasseur, M.Sc.**

IRIDIA-Labor, Ecole Polytechnique, Université Libre de Bruxelles, Brüssel, Belgien

Guillaume Levasseur ist Mitarbeiter im IRIDIA-Labor der Ecole Polytechnique der Universität Brüssel (ULB). Forschungsschwerpunkte: verteilte Datenbanken, Machine Learning, Data Mining, Energiebedarf in Haushalten.

**Dr.-Ing. Michael Frey**

Institut für Fahrzeugsystemtechnik, Karlsruher Institut für Technologie, Karlsruhe

Dr.-Ing. Michael Frey ist stellvertretender Institutsleiter am Institut für Fahrzeugsystemtechnik, Teilinstitut Fahrzeugtechnik am Karlsruher Institut für Technologie (KIT). Forschungsschwerpunkte: Fahrwerk, Fahrzeugkonzepte, Fahrzeugmodellierung, Betriebsstrategien.

**Prof. Dr. rer. nat. Frank Gauterin**

Institut für Fahrzeugsystemtechnik, Karlsruher Institut für Technologie, Karlsruhe

Prof. Dr. rer. nat. Frank Gauterin ist Institutsleiter am Institut für Fahrzeugsystemtechnik, Teilinstitut Fahrzeugtechnik am Karlsruher Institut für Technologie (KIT). Forschungsschwerpunkte: Fahrzeugregelung, Fahrzeugdynamik, Reifen-Fahrbahn-Kontakt, Noise-Vibration-Harshness.

**apl. Prof. Dr.-Ing. Ralf Mikut**

Institut für Angewandte Informatik, Karlsruher Institut für Technologie, Karlsruhe

apl. Prof. Dr.-Ing. Ralf Mikut ist Fachgebietsleiter am Institut für Angewandte Informatik (IAI) am Karlsruher Institut für Technologie (KIT). Forschungsschwerpunkte: Machine Learning, Data Mining, Robotik, Modellierung von Energiesystemen.

**PD Dr.-Ing. Markus Reischl**

Institut für Angewandte Informatik, Karlsruher Institut für Technologie, Hermann von Helmholtz Platz 1, 76344 Eggenstein, Tel.: +49 721 60825749, Fax: +49 721 60825786  
[markus.reischl@kit.edu](mailto:markus.reischl@kit.edu)

PD Dr.-Ing. Markus Reischl ist Projektleiter am Institut für Angewandte Informatik (IAI) am Karlsruher Institut für Technologie (KIT). Forschungsschwerpunkte: Mensch-Maschine-Schnittstellen, Bildverarbeitung, Machine Learning, Data Mining.