
Multisensorische Straßenzustandsanalyse mittels Lastenrad - Aus dem Projekt R4R

Mahmoud Laghbani, Stephan Schmidt, Dimitar Iliev

Siehe Autorinnenangaben

Abstract

Die kontinuierliche Überwachung des Straßenzustandes ist für den sicheren, komfortablen und effizienten Betrieb von autonomen Mikromobilen von entscheidender Bedeutung. Im Rahmen dieser Studie wurde ein Algorithmus zur Straßenzustandsanalyse, auf Basis von Beschleunigungs- und GPS-Daten entwickelt. Der Algorithmus wurde an realen Daten getestet, die mit einem autonomen Lastenfahrzeug aufgezeichnet wurden. Die Ergebnisse erlauben den Zustand der befahrenen Straße zu visualisieren und objektiv zu bewerten.

Schlagwörter / Keywords:

Autonomes Mikrofahrzeug, ROS2, Vibrations- und Komfortbewertung, Smart City, R4R Projekt

1. Einleitung

Eine umfassende Kenntnis über den Zustand von Straßen und Radwegen ermöglicht es, Fahrsicherheit und Komfort, insbesondere für RadfahrerInnen, sicherzustellen. Beschädigte oder unebene Fahrbahnoberflächen können Unfälle verursachen und mindern den Komfort. Traditionell werden Straßenschäden durch manuelle Begehungen oder mit speziellen Messfahrzeugen erfasst. Diese Verfahren sind jedoch sehr aufwendig, da sie viel Zeit und personelle Ressourcen erfordern (Ahmed et al., 2024). Zudem stoßen konventionelle Messfahrzeuge in engen Gassen oder auf Fahrradwegen an ihre Grenzen, da sie dort gar nicht oder nur eingeschränkt einsetzbar sind. Hier bietet der Einsatz eines speziell instrumentierten Lastenrads Vorteile: Selbst schmale Wege sind zugänglich, die Messung erfolgt aus Perspektive eines Radfahrenden, und die Akzeptanz eines Fahrrads im Radverkehr ist höher als die eines Autos (Saleh, 2025).

Verschiedene Forschungsarbeiten haben gezeigt, dass mit instrumentierten Fahrrädern (engl. Instrumented Probe Bikes, IPB) präzise Daten zur Fahrbahnbeschaffenheit gewonnen werden können. So wurden z.B. Fahrräder mit GPS-Empfängern, Beschleunigungssensoren und Kameras eingesetzt, um Vibrationen und Oberflächenprofile von Radwegen aufzuzeichnen (Ahmed et al., 2024; Schnabel et al., 2024).

Im Rahmen des vom Bundesministerium für Digitales und Verkehr geförderten Projektes R4R (Ready for Smart City Robots) wird der Ansatz verfolgt community-basiert Umgebungsdaten zu sammeln, die für zukünftige Mobilität und Logistik in der Smart City erforderlich sind (Zug, 2022). Exemplarisch erweitert wird diese visionäre Zielstellung durch die Motivation hochautomatisiert fahrende Fahrräder oder Mikroroboter zum Betrieb von Mietfahrradsystemen im ländlichen Raum einzusetzen (Landratsamt Nordsachsen, 2023). Hierzu wurden unterschiedliche Sensorplattformen wie Mikroroboter und Lastenrädern erprobt, um während der Fahrt kontinuierlich Infrastrukturdaten zu erfassen.

Das R4R-Lastenrad soll Referenzdaten für diese Informationen bereitstellen und damit die Frage beantworten, ob unsere Städte bereit für Roboter sind. Neu ist dabei insbesondere der Community-Ansatz, bei dem die Sensorplattform kostengünstig auf Standardfahrrädern montiert werden kann. Damit lässt sich eine großflächige Datenerfassung realisieren, ohne teure Spezialfahrzeuge einsetzen zu müssen.

Dieser multisensorische Ansatz ermöglicht es, unterschiedliche Datentypen – von Erschütterungs- und Lagedaten über visuelle Informationen bis hin zu präzisen Positionsdaten – zu analysieren. Die zentrale Hypothese lautet, dass durch die Fusion mehrerer Sensorquellen der Straßenzustand zuverlässiger und

detaillierter bestimmt werden kann als mit einzelnen Sensoren. Insbesondere im Kontext autonomer Lieferroboter, die im öffentlichen Raum auf Geh- und Radwegen operieren sollen, ist eine lückenlose Kenntnis der Wegbeschaffenheit essenziell: Bildverarbeitungsalgorithmen solcher Roboter benötigen etwa Informationen darüber, ob sie sich auf Asphalt, Kopfsteinpflaster oder Schotter bewegen, da unebene Untergründe die Trajektorienplanung und Stabilität stark beeinflussen (Schmid, 2019). Das R4R-Lastenrad soll Referenzdaten für diese Informationen bereitstellen und damit die Frage beantworten, ob unsere Städte bereit für Roboter sind.

2. Qualität von Radverkehrsanlagen in Deutschland

Neuere Studien betonen, dass die Qualität von Radverkehrsanlagen entscheidend für Komfort und Sicherheit von Radfahrenden ist. Radwege mit baulicher Trennung vom Kfz-Verkehr werden von Nutzen als deutlich sicherer und komfortabler empfunden als solche im Mischverkehr. In einer Umfrage bewerteten 867 Radfahrende einen räumlich getrennten, asphaltierten Radweg als mit Abstand am akzeptabelsten, während Führung direkt auf der Fahrbahn am schlechtesten abschnitt (Merz, 2021).

Auch der ADFC-Fahrradklima-Test 2016 ergab, dass 72 % der Radfahrenden eine Trennung vom Autoverkehr für wichtig oder sehr wichtig halten (Stork et al., 2019). Fehlt eine qualitativ gute Infrastruktur, fühlen sich viele unsicher (Stork et al., 2019) – dies bremst den Umstieg aufs Fahrrad (Bengel, 2022). Objektiv zeigen Untersuchungen, dass schmale oder nur markierte Radfahrstreifen oft zu riskant geringen Überholabständen durch Kfz führen, (Richter et al., 2019), was die Verkehrssicherheit mindert.

Zur Beurteilung der Infrastrukturqualität werden mehrere Kriterien herangezogen, darunter Oberflächenbeschaffenheit, Breite, Sicherheit und Markierungen:

- **Oberfläche:** Eine glatte, ebene und rutschfeste Fahrbahn (bevorzugt Asphalt) erhöht Komfort und Ganzjahresnutzbarkeit (Morelli, 2022). Tatsächlich ist eine hochwertige Oberfläche für fast alle Radfahrenden ein entscheidendes Kriterium bei der Routenwahl (Klein, 2021).
- **Breite:** Ausreichende Breite ermöglicht sicheres Überholen und Nebeneinanderfahren. Moderne Empfehlungen fordern breitere Radwege, um zügiges und komfortables Fahren – auch mit Lastenrädern – zu gewährleisten (Stork et al., 2019).
- **Sicherheit:** Klare Trennung vom Kfz-Verkehr (baulich oder durch Schutzelemente) sowie sichere Kreuzungsgestaltung erhöhen die objektive und subjektive Sicherheit (Merz, 2021).

- **Markierungen:** Deutliche Markierungen (z. B. farbige Radfahrstreifen an Knotenpunkten) verbessern Sichtbarkeit und Orientierung im Verkehr

Aktuelle Entwicklungen in Deutschland – wie der Bau von Radschnellwegen – setzen auf hohe Qualitätsstandards (große Breiten, kreuzungsarme Führungen, Beleuchtung), um Komfort und Sicherheit im Radverkehr weiter zu steigern (Morelli, 2022).

3. Grundlagen

Mechanische Schwingungen treten in nahezu allen mobilen Anwendungen auf und wirken sich dabei nicht nur auf die Strukturmechanik von Fahrzeugen oder Robotern aus, sondern beeinflussen insbesondere das Komfortempfinden des Menschen (Wang et al., 2022). Aus diesem Grund existieren in der Fachliteratur sowie in Normen und Richtlinien (z. B. (ISO 2631-1, 1997), (VDI-2057, 2017), (ISO-8608, 2016)) umfangreiche Vorgaben, wie Schwingungsdaten sowohl messtechnisch zu erfassen als auch hinsichtlich Komfort- und Gesundheitsaspekten auszuwerten sind. Um Straßenzustände an Orten, an denen Unbehagen oder gesundheitliche Probleme auftreten können, angemessen zu bewerten, bedarf es jedoch neben den Beschleunigungsdaten auch zusätzlicher Sensordaten, beispielsweise Punktwolken und Kamerabilder (Maeda et al., 2018).

Im Folgenden werden die theoretischen Grundlagen erläutert, die für den entwickelten Algorithmus zur Straßenzustandsanalyse von Bedeutung sind. Dazu zählen die Frequenzbewertung, die Berechnung von RMS-Werten, die Klassifikation von Komfortstufen, die Bestimmung der Tagesbelastung, Methoden der Peak-Detektion sowie die Synchronisation von Bild- und Punktwolkendaten.

Zu Beginn liegt üblicherweise ein Messsignal $a(t)$ als zeitabhängige Beschleunigung vor (in $\frac{m}{s^2}$). Um einerseits mechanische Frequenzanteile sachgerecht zu berücksichtigen und andererseits das Empfinden des Menschen einzubeziehen, werden Frequenzbewertungsfunktionen eingesetzt.

Nach VDI 2057 und ISO 2631 werden unterschiedliche Frequenzgewichte $W_k(f)$ und $W_d(f)$ verwendet, um die menschliche Empfindlichkeit gegenüber bestimmten Frequenzbereichen in die Bewertung einzubeziehen:

- $W_k(f)$: für die vertikale Schwingung (z-Achse)
- $W_d(f)$: für die horizontale Schwingung (x, y-Achsen)

Zur Bewertung eines pro Achse vorliegenden Zeitsignals $a(t)$ kann entweder eine zeitbereichsbasierte Faltung mit der Impulsantwort des entsprechenden

Filters oder eine Multiplikation im Frequenzraum mittels Fourier-Transformation (FFT) erfolgen. Mathematisch lässt sich dies wie folgt ausdrücken:

$$\hat{A}_w(f) = \hat{A}(f) \cdot W(f)$$

Wobei $\hat{A}(f)$ die Fourier-transformierte des Rohsignals $a(t)$ ist und $W(f)$ die normabhängige Gewichtungsfunktion (z. B. $W_k(f)$ oder $W_d(f)$).

Um stoßartige Schwingungen in Echtzeit zu erfassen, empfiehlt VDI 2057 den Einsatz einer exponentiellen Mittelung anstelle eines festen gleitenden Fensters. Im kontinuierlichen Fall wird hierfür folgende Formel angewendet:

$$a_{w,\tau}(t) = \sqrt{\frac{1}{\tau} \int_0^t a_w^2(\xi) \exp\left(-\frac{\xi-t}{\tau}\right) d\xi}$$

Hierbei bezeichnet ξ die Integrationsvariable (die Zeit) und τ die Integrationszeitkonstante für die gleitende Mittelung. Zur digitalen Verarbeitung zerlegt man t in Schritte $n \Delta t$ mit Abtastfrequenz $f_s = \frac{1}{\Delta t}$. Daraus ergibt sich der Glättungsparameter:

$$\alpha = \frac{1}{\tau f_s} = \frac{\Delta t}{\tau}$$

Dann lässt sich das Integral in eine rekursive Differenzgleichung überführen, wo man z. B. eine Hilfsvariable

$$y_n = \frac{1}{\tau} \int_0^{n \Delta t} a_w^2(\xi) \exp\left(-\frac{\xi - n \Delta t}{\tau}\right) d\xi$$

diskret approximiert durch:

$$y_n = (1 - \alpha)y_{n-1} + \alpha \cdot a_w^2(n \Delta t)$$

Aus y_n wird dann

$$a_{w,\tau}(n \Delta t) = \sqrt{y_n}$$

So entsteht ein gleitender exponentieller RMS-Wert, der sprunghafte Änderungen zeitnah abbildet.

Um schließlich eine Kennzahl für die Belastung der gesamten Achse zu erhalten, wird (nach ISO/VDI) oft folgender Summenwert gebildet:

$$a_{wv} = \sqrt{(k_x \cdot a_{wx})^2 + (k_y \cdot a_{wy})^2 + (k_z \cdot a_{wz})^2}$$

Wobei a_{wx} , a_{wy} , a_{wz} die exponentiell geglätteten RMS-Werte in den drei Richtungen sind. Die Faktoren k_x, k_y, k_z können angepasst werden, um verschiedene Empfindlichkeiten zu gewichten. In VDI 2057 ist es für gesundheitliche Bewertungen empfohlen, $k_x = k_y = 1.4$ und $k_z = 1$ zu verwenden. Für reine Komfortuntersuchungen, wie in diesem Beitrag sind $k_x = k_y = k_z = 1$ üblich.

Zur Bewertung kurzzeitiger, stoßartiger Belastungen durch Vibrationen sind in der Schwingungsmesstechnik zwei Herangehensweisen verbreitet. Aus dem zeitabhängigen Schwingungssignal $a_{wv}(t)$ wird zunächst der Betragsmaximalwert

$$\max|a_{wv}(t)|$$

ermittelt. Er gibt den höchsten gemessenen Stoß an – also das Maximum aller Beschleunigungswerte über die Messdauer.

Neben dem einen globalen Maximum kann man auch alle lokalen Maxima erfassen, sofern sie einen bestimmten Schwellwert S überschreiten. In realen Fahrsituationen zeigen sich oft mehrere starke Erschütterungen an verschiedenen Stellen der Straße:

- Schlaglöcher, Querrillen, Bordsteinkanten oder Bodenschwellen können zu wiederholten Peaks im Signal führen.
- Über die Anzahl dieser Peaks und deren Abstand voneinander lässt sich abschätzen, wie „ruppig“ oder „uneben“ ein Streckenabschnitt ausfällt.

Die Kombination der Vibrationsdaten mit visuellen und geometrischen Informationen (Kamerabilder, Punktwolken) ermöglicht eine präzise Lokalisierung und Dokumentation von Straßenschäden sowie weiteren Ursachen von Komforteinbußen.

Stößereignisse wirken sich unmittelbar auf das Komfortempfinden und potenziell auch auf die Gesundheit aus. Um zu messen, wie unkomfortabel die Fahrt ist, wurden in ISO 2631 folgende Komfortschwellenwerte (c) definiert:

$$c = \begin{cases} \text{Komfortabel} & \text{wenn } a_{wv} < 0.315 \\ \text{Leicht unkomfortabel} & \text{wenn } 0.315 \leq a_{wv} < 0.63 \\ \text{Unkomfortabel} & \text{wenn } 0.63 \leq a_{wv} < 0.8 \\ \text{Sehr unkomfortabel} & \text{wenn } a_{wv} \geq 0.8 \end{cases}$$

Da sich diese Schwellenwerte in ISO 2631 jedoch hauptsächlich an Kraftfahrzeuge orientieren, existieren für Radfahrende teilweise abweichende Grenzen. Forschungsergebnisse wie die von (Gao et al., 2018) zeigen etwa folgende Schwellenwerte:

$$c = \begin{cases} \text{"Komfortabel"} & \text{wenn } a_{wv} < 1,72 \text{ m/s}^2 \\ \text{"Leicht unkomfortabel"} & \text{wenn } 1,72 \text{ m/s}^2 \leq a_{wv} < 2,12 \text{ m/s}^2 \\ \text{"Unkomfortabel"} & \text{wenn } 2,12 \text{ m/s}^2 \leq a_{wv} < 2,54 \text{ m/s}^2 \\ \text{"Sehr unkomfortabel"} & \text{wenn } 2,54 \text{ m/s}^2 \leq a_{wv} < 3,19 \text{ m/s}^2 \\ \text{"Extrem unkomfortabel"} & \text{wenn } a_{wv} \geq 3,19 \text{ m/s}^2 \end{cases}$$

4. Methode und Implementierung

Der entwickelte Algorithmus soll perspektivisch in eine benutzerfreundliche Webplattform integriert werden. Daher wurde besonderer Wert daraufgelegt, die Datenströme aus Punktwolken, Kamerabildern und Beschleunigungssensoren automatisch zu durchsuchen, zu filtern und zeitsynchron zusammenzuführen. Die praktische Erprobung dieses Verfahrens erfolgte anhand eines autonomen Lastenrads aus dem Projekt R4R, das mit folgenden Sensoren ausgestattet ist:

- **IMU (Inertial Measurement Unit):** zeichnet Beschleunigung und Winkelgeschwindigkeiten in drei Achsen auf.
- **GNSS/GPS-Modul:** ermöglicht eine kontinuierliche Positions- und Zeitreferenz.
- **LiDAR-Sensor:** erfasst eine hochaufgelöste 3D-Punktwolke der Umgebung.
- **Kamera:** liefert Videobilder zur optischen Dokumentation des Streckenzustands.

Abbildung 1 zeigt den Sensorträger, der für die Datenerfassung verwendet wurde. Die Dateien sind auf Basis von ROS2 (Robot Operating System 2) aufgenommen. Weitere Spezifikationen und Informationen zum Sensorträger finden sich in (Laghbani et al., 2025).



Abbildung 1: Sensorträgerplattform (Lastenrad) (Laghbani et al., 2025)

Zu Beginn dieser Arbeit wurde eine benutzerfreundliche GUI (siehe Abbildung 2) entwickelt, die alle notwendigen Schritte – von der ROS2-Bag-Dateiauswahl bis hin zur tiefgehenden Analyse und automatisierten Berichterstellung – in einer einheitlichen Oberfläche zusammenführt. Die GUI bietet benutzerdefinierbare Parameter für Filter, Schwellwerte, Sensorauswahl und unterstützt eine interaktive 3D-Visualisierung. Dadurch wird eine effiziente Datenexploration sichergestellt, die ohne tiefere Programmierkenntnisse genutzt werden kann.

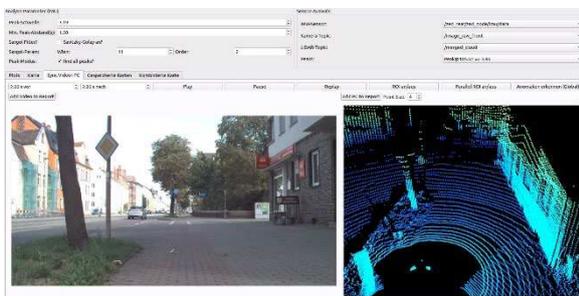


Abbildung 2: Übersicht der entwickelten GUI mit Tabs für „Plots“, „Karte“ sowie „Sync-Video+PC“ und weiteren Funktionen wie RANSAC-Parametrierung und Berichts-Export

Im Rahmen dieser Arbeit wird ein softwarebasierter Ansatz entwickelt, der sämtliche Sensordaten aus ROS2-Bag-Dateien bezieht und zu einer ganzheitlichen Straßenzustandsanalyse verarbeitet. Dabei

kommen mehrere Module und Funktionen zum Einsatz, um die Daten zu laden, zu filtern und letztlich aufzubereiten. Eine schematische Darstellung des Prozesses verdeutlicht die einzelnen Schritte (Siehe Abbildung 3).

Zuerst werden die Daten aus einer ROS2-Bag-Datei eingelesen. Die aktuelle Version des Algorithmus unterstützt dabei das SQLite3-Format (*.db3). Dieser Schritt erfolgt mithilfe der ROS2-Python-API (rosbag2_py). Das Skript erkennt automatisch die ROS2-Topics mit den Typen

- sensor_msgs/msg/Imu,
- sensor_msgs/msg/NavSatFix,
- sensor_msgs/msg/Image oder
- sensor_msgs/msg/PointCloud2

Aus jeder eingehenden Nachricht werden anschließend die relevanten Felder extrahiert (z. B. die lineare Beschleunigung bei IMU(Inertiale Messeinheit (engl. Inertial measurement unit))) und in Pandas-DataFrames überführt. Anschließend erfolgen eine zeitliche Sortierung sowie weitere Vorbereitungen für die nachfolgende Auswertung. Innerhalb des Skripts werden diese Felder jeweils an die relevanten Stellen weitergereicht.

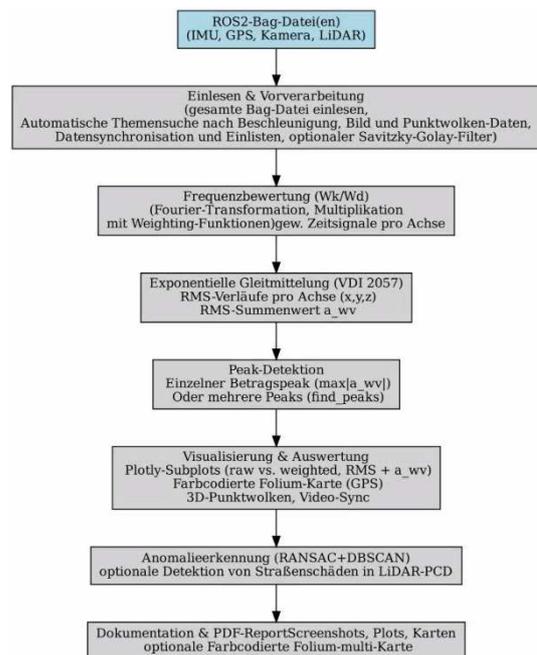


Abbildung 3: Flussdiagramm des Prozesses verdeutlicht die einzelnen Schritte des Algorithmus

Um alle Sensorwerte in einen einheitlichen Zeitbezug zu bringen, wird zunächst auf den ersten GPS-Datensatz gewartet. Dessen Zeitstempel dient als Referenz, an die alle weiteren (nicht-GPS-)Nachrichten – z. B. von IMU, Kamera oder LiDAR – mithilfe eines gleitenden Durchschnitts-Offsets angepasst werden. Kurzfristige Schwankungen werden abgefedert, in-

dem jeweils nur die letzten N (z. B. 10) Differenzwerte Δt gemittelt und ältere Offsets verworfen werden. Sobald alle Daten in Pandas-DataFrames vorliegen, wird anhand des jeweils kleinsten Zeitwerts pro Sensor ein globales Minimum bestimmt, sodass der früheste Messpunkt bei ($t=0$ s) liegt. Anschließend sortiert man die DataFrames chronologisch, wodurch sich Ereignisse (z. B. Beschleunigungsspeaks) samt passender GPS-Koordinaten leicht verknüpfen lassen. Für eine übersichtliche Auswertung liegen IMU, GPS, Kamera und LiDAR in separaten DataFrames (siehe Tabelle 1) vor. So lässt sich etwa für einen Peak das Zeitfenster z. B. $[t_{\text{peak}} - 2, t_{\text{peak}} + 2]$ filtern, wobei das GUI diese Grenzen bei Bedarf anpasst.

Tabelle 1: Übersicht der DataFrames und zugehörige Spalten

DataFrame	Spalten
imu_df (IMU-Daten)	timestamp topic accel_x accel_y accel_z
gps_df (GPS-Koordinaten)	Timestamp topic latitude longitude altitude
img_df (Kamerabilder)	timestamp topic image_msg
pc_df (LiDAR-Punktwolken)	timestamp topic pointcloud_msg

Die vorbereiteten Beschleunigungssignale pro Achse (x, y, z) werden schließlich frequenzgewichtet, um dem menschlichen Komfortempfinden Rechnung zu tragen. Das Skript kombiniert eine schnelle Fourier-Transformation (FFT) mit vorab geladenen W_k/W_d -Funktionen, die in einem CSV hinterlegt sind. Für die z-Achse kommt dann W_k zur Anwendung, für die x- und y-Achse jeweils W_d . Nach Multiplikation im Frequenzraum erfolgt eine inverse FFT, sodass in der Zeitdomäne gewichtete Signale $a_w(t)$ entstehen (Oppenheim and Schafer, 2010), (Rockmore, 2000). Anschließend wird eine exponentielle Gleitmittelung zur RMS-Bestimmung nach VDI 2057 vorgenommen. Die Integrationszeit τ kann hier in Sekundenschritten gewählt werden. Mit fortschreitenden Zeitschritten aktualisiert man den RMS-Wert laufend, ohne ein streng festes Zeitfenster zu verschieben. Dadurch ist

das Ergebnis adaptiver gegenüber sprunghaften Änderungen. Für jede Achse liegt am Ende ein exponentiell gemittelt RMS-Signal vor (a_{wx}, a_{wy}, a_{wz}), das dann über eine Wurzel-Summen-Quadrat-Beziehung in einen Gesamtwert a_{wv} überführt wird. Abhängig von der Peak-Detektionseinstellung werden die hohen Beschleunigungsspitzen in diesem Summensignal $a_{wv}(t)$ entweder als einziger Betragspeak $\max|a_{wv}(t)|$ bestimmt oder, bei Mehrfachsuche, über die *SciPy-Funktion find_peaks(...)* als mehrere lokale Maxima erkannt. Dabei kann eine Schwellwert-Höhe (Peak-Schwelle) und ein minimaler Zeitabstand der Peaks in Sekunden in GUI-Fenster vorgegeben werden. Aus dem größten Peak gewinnt man auf Wunsch auch den Crestfaktor, indem man das Verhältnis von $\max|a_{wv}(t)|$ zu seinem RMS-Gesamtwert bildet. Zur Darstellung der Ergebnisse werden in einem ersten Schritt Plotly-Subplots erzeugt, in denen man u. a. folgende Kurven parallel sieht:

- Rohbeschleunigung x,y,z
- Frequenzbewertete(gewichtetet) Signale
- Exponentielle RMS-Verläufe der drei Achsen
- Summenwert $a_{wv}(t)$ in einem separaten Teil-Plot, ggf. farbig codiert nach Komfort-Grenzen. Peak-Ereignisse werden als schwarze Sterne visualisiert (Abbildung 4).

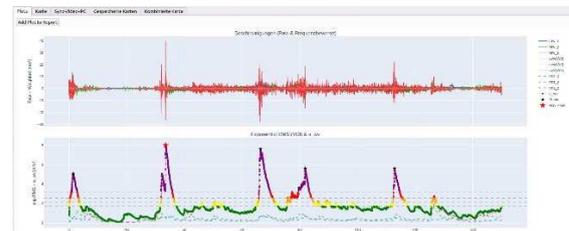


Abbildung 4: 3-Achsen-Schwingungsanalyse: Roh- und Frequenzbewertete Beschleunigungen (W_k/W_d) mit Exponential-RMS und Peak-Erkennung

Parallel wird aus den GPS-Koordinaten eine Folium-Karte erstellt, auf der jeder Datensatz zeitkorreliert platziert wird. Punkte, deren Zeit in zeitlicher Nähe zu einem ermittelten Peak liegt, erhalten z. B. einen Sternmarker statt eines farbigen Kreises. Auf diese Weise kann man genau sehen, an welcher geografischen Position starke Erschütterungen auftraten (siehe Abbildung 5).



Abbildung 5: GPS-Karte mit farbcodierter Vibrationsbewertung entlang der Strecke, die Komfortbereiche: grün

(komfortabel), gelb (leicht unkomfortabel), orange (unkomfortabel), rot (sehr unkomfortabel) und lila (extrem unkomfortabel).

Zur tieferen Analyse steht in einem weiteren Tab die Möglichkeit zur Video-/Punktwolken-Synchronisierung bereit. Das Skript filtert auf Basis ausgewählter Zeitfenster (z. B. ± 2 s um den Peak) die jeweiligen Kamera-Frames (Topics sensor_msgs/msg/Image) sowie LiDAR-Punktwolken (Topics sensor_msgs/msg/PointCloud2). Beide Sequenzen lassen sich nebeneinander abspielen. Ein optionaler ROI-Modus ermöglicht es zudem, im 3D-Fenster einen rechteckförmigen Bereich zu markieren und die selektierten Punkte statistisch (z. B. Abstände, Höhenverteilung) auszuwerten (Abbildung 6).

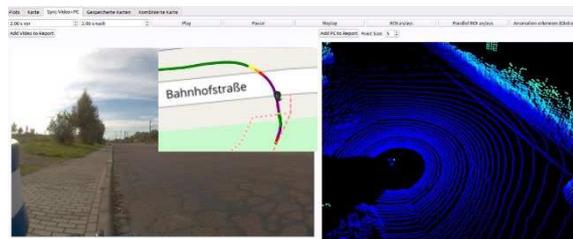


Abbildung 6: Synchronisierte Mehrsensor-Daten (GPS-Karte, Kameraansicht, LiDAR-Punktwolke) zur Straßenzustandsanalyse

Ein weiterer optionaler Baustein ist die 3D-Anomaliedetektion: Mithilfe von RANSAC wird in der Punktwolke eine Hauptebene identifiziert, wobei meist angenommen wird, dass diese der Fahrbahn entspricht. Anschließend gruppiert ein DBSCAN-Algorithmus alle jenseits dieser Ebene liegenden Ausreißer. Dies kann etwa zur Detektion von Schlaglöchern (tiefe Bereiche) oder anderer Straßenschäden verwendet werden (Abbildung 7).

Eine Eigenschaft im System ist die Möglichkeit, mehrere zuvor gespeicherte Karten zu einer kombinierten Karte zusammenzuführen. Über den entsprechenden GUI-Tab („Kombinierte Karte“) kann der Benutzer aus einer Liste gespeicherter Karten (sowie deren zugehöriger GPS- und Peaks-Daten im CSV-Format) mehrere Karten auswählen. Beim Zusammenführen werden die Daten aus den einzelnen Karten zunächst in einem einheitlichen DataFrame konsolidiert. Dabei werden Duplikate (basierend auf Zeitstempel und Koordinaten) entfernt und die Datensätze chronologisch sortiert. Anschließend wird mit Hilfe der Folium-Bibliothek eine neue, kombinierte Karte generiert, auf der alle GPS-Datenpunkte dargestellt werden. Die Marker werden farbcodiert – entsprechend dem berechneten Vibrationswert – und spezielle Ereignisse (z. B. Peak-Ereignisse) werden zusätzlich mit einem Stern markiert. Dadurch entsteht eine übersichtliche und umfassende Darstellung der

räumlichen Verteilung von Straßenzustandsdaten über mehrere Messfahrten hinweg (Abbildung 8).

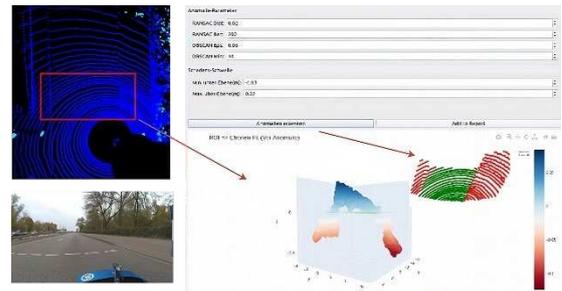


Abbildung 7: Interaktive ROI-Auswahl in der LiDAR-Punktwolke mit RANSAC/DBSCAN-Parametern und gleichzeitiger Videovorschau zur 3D-Anomalieerkennung

Abschließend können alle generierten Inhalte, darunter Diagramme, Karten-Screenshots und ggf. andere GUI-Ansichten, in einem PDF-Report zusammengeführt werden. Das Skript übernimmt hierfür Screenshots, Titel und Kurzbeschreibungen der jeweiligen Themen (z. B. IMU-Sensorname, Peak-Schwellwert oder LiDAR-Topic). Man erhält damit eine in sich geschlossene Dokumentation der durchgeführten Messungen und Analysen.

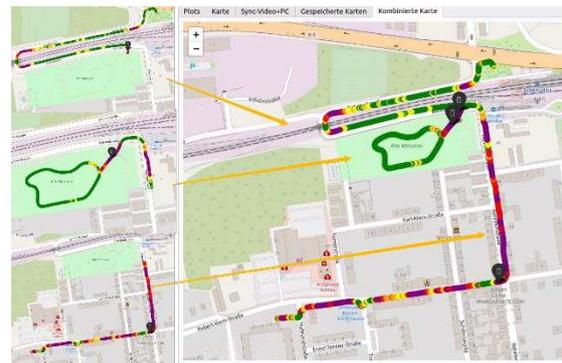


Abbildung 8: Mehrere gespeicherte Karten als „Kombinierte Karte“ mit farbcodierten Vibrationswerten und markierten Peak-Ereignissen

Durch diese Zusammenstellung von mehreren Teilkomponenten (Bag-Lesen, IMU-Frequenzbewertung, exponentielle RMS, Peak-Detektion, Folium-Karte, Video-/PointCloud-Sync, RANSAC+DBSCAN, PDF-Export) ergibt sich ein modularer, aber zugleich eng verzahnter Analyse-Workflow. Dieser erlaubt eine flexible Parametrisierung (Filterlängen, Schwellwerte, Achs-Gewichte etc.) sowie eine tiefgehende wissenschaftliche Auswertung und Visualisierung von Straßenzustandsdaten.

5. Validierung

Um die Zuverlässigkeit und Genauigkeit des beschriebenen Verfahrens zusätzlich zu prüfen, wurde darüber hinaus ein künstlicher Referenz-Parkour aufgebaut und vermessen. Dieser Parkour enthält bekannte Hindernisse, etwa eine mobile Bodenschwelle

(„Speed Bump“). Dank dieser definierten Unebenheiten lässt sich exakt nachvollziehen, welche Beschleunigungspeaks (IMU-Daten) und Geometrieausreißer (in der LiDAR-Punktwolke) beim Überfahren auftreten.

Während der Testfahrten auf diesem Referenz-Parkour wurden IMU-, GPS-, Kamera- und LiDAR-Daten aufgezeichnet und mit den erwarteten Schwellwerten abgeglichen. Die Straßenschwellen ließen sich in den Analyseplots als signifikante Peaks in $a_{wv}(t)$ erkennen und in der zugehörigen Kartenansicht durch farblich markierte Punkte lokalisieren (Abbildung 9).

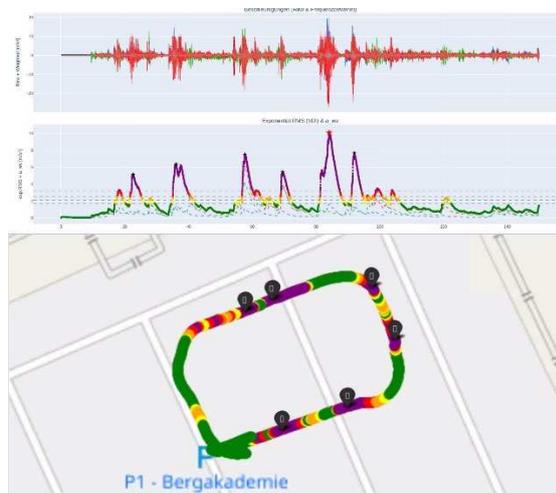


Abbildung 9: Verknüpfte Darstellung von Roh- und frequenzbewerteten Beschleunigungssignalen (oben), Exponentielle RMS (Mitte) und farbcodierten GPS-Stützpunkten (unten) auf dem Referenz-Parkour. Deutliche Peaks in $a_{wv}(t)$ korrespondieren mit der Überfahrt einer Bodenschwelle.

Die synchronisierte Darstellung von Punktwolke und Videobild zeigt darüber hinaus deutlich, dass zu genau den Zeitpunkten, an denen hohe Beschleunigungswerte (Peaks) registriert wurden, im Videostream auch die Bodenschwelle sichtbar ist. Mithilfe der ROI-Auswahl in der LiDAR-Punktwolke mittels RANSAC/DBSCAN lässt sich die Bodenschwelle als rote Ausreißer („Outliers“) geometrisch visualisieren.

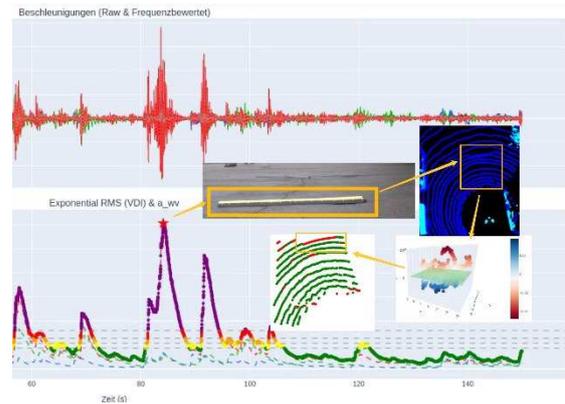


Abbildung 10: Kombinierte Auswertung von Roh- und frequenzbewerteten Beschleunigungen, Exponentielle RMS und LiDAR/Kameradaten sowie ROI-Auswahl in der LiDAR-Punktwolke mit RANSAC/DBSCAN.

6. Ergebnisse und Auswertungen

Mit dem Lastenrad wurden in drei verschiedenen Städten – Merseburg, Köthen und Schkeuditz – Messfahrten durchgeführt. Jede Messfahrt umfasste in der Regel rund 150 Sekunden an Sensordaten, sodass für jede Stadt mehrere Teilaufnahmen zur Verfügung standen. Im Rahmen des Projektes wurden großflächig Daten erhoben und ausgewertet. Die Kombination aus mehreren Karten ermöglicht, final eine kartografische Visualisierung des gesamten Stadtgebietes.

Hierbei wird der Straßenzustand und das Komfortlevel farblich kodiert. Wenn ein Abschnitt lila markiert ist, bedeutet dies, dass dieser Straßenabschnitt in einem schlechten Zustand und somit für FahrradfahrerInnen unangenehm zu befahren ist. Hingegen zeigt eine grüne Markierung an, dass dieser Abschnitt der Straße ein komfortables Fahrerlebnis bietet.

In jeder 150-Sekunden-Einheit werden zudem die maximalen Spitzenwerte dargestellt, um hervorzuheben, welche Bereiche besonders berücksichtigt werden sollten. Dabei ist zu beachten, dass der Algorithmus in der aktuellen Version noch nicht klassifiziert, ob diese Spitzenwerte durch Schlaglöcher, Bodenwellen oder Bordsteinkanten verursacht werden. Daher sollten zur Auswertung immer die synchronisierten Videos und die Punktwolke zurate gezogen werden, um die Ursache der Spitzenwerte zu bestimmen. In den folgenden drei Bildern sind die finalen Karten und Auswertungen für die drei Städte zu sehen.

Die Ergebnisse in der Abbildung 11 zeigen, dass die im Innenstadtbereich von Köthen durchgängig violett eingefärbten Straßensegmente auf eine sehr hohe Vibrationsbelastung hindeuten, die nach unserer Klassifikation als „extrem unkomfortabel“ einzustufen ist. Aus Radfahrersicht liegt die Hauptursache

hierfür häufig am Kopfsteinpflaster bzw. an historischen Steinbelägen in diesem Gebiet. Solche Beläge erzeugen bei Fahrrädern deutlich höhere Stoßspitzen als glatte Asphaltflächen, da sie Unebenheiten und Fugen beinhalten, die fortwährend für Vibrationen sorgen. Außerhalb der Altstadtregion zeigt die Analyse mehrheitlich grüne und gelbe Bereiche, was auf komfortablere Bedingungen für Fahrradfahrende schließen lässt.



Abbildung 11: Komfortbewertung aus Fahrradfahrerperspektive – Köthen

In Schkeuditz überwiegen grün/gelb markierte, komfortable Abschnitte, während rot/violett gekennzeichnete Bereiche im Zentrum auf starke Erschütterungen und damit „sehr bis extrem unkomfortable“ Bedingungen für Radfahrende hinweisen (siehe Abbildung 12).



Abbildung 12: Komfortbewertung aus Fahrradfahrerperspektive – Schkeuditz

Merseburg weist im Vergleich zu den zuvor betrachteten Städten mehrheitlich grüne Abschnitte auf, die auf ein insgesamt komfortables Fahrgefühl schließen lassen, während nur vereinzelt rote/violette Strecken mit „sehr bis extrem unkomfortablen“ Erschütterungen auftreten (siehe Abbildung 13).



Abbildung 13: Komfortbewertung aus Fahrradfahrerperspektive – Merseburg

7. Fazit und Verbesserungspotenziale

Zusammenfassend lässt sich festhalten, dass eine kontinuierliche und detaillierte Erfassung des Straßenzustands von entscheidender Bedeutung für den sicheren und komfortablen Einsatz autonomer Mikromobile ist. Die Studie hat gezeigt, dass durch regelmäßige Zustandserfassung unebene Stellen erkannt und in der Routenplanung oder Fahrdynamik berücksichtigt werden können. Als Messplattform bewährte sich dabei ein mit Sensorik ausgestattetes Lastenrad, das sich als äußerst flexible Lösung erwiesen hat (Saleh, 2025). Der Einsatz eines solchen Fahrzeugs ermöglicht eine kontinuierliche Aktualisierung in Echtzeit, was für eine vorausschauende Wartung der Verkehrsinfrastruktur essenziell ist.

Die im Rahmen der Arbeit entwickelten Algorithmen zur Vibrationsanalyse und Komfortbewertung erwiesen sich als effektiv, um die Fahrqualität auf verschiedenen Straßenbelägen objektiv zu beurteilen. Unterschiede im Straßenzustand konnten anhand der Sensordaten detektiert und quantifiziert werden, wodurch eine fundierte Bewertung des Fahrkomforts möglich wurde. Durch die Verknüpfung der Beschleunigungs- und Vibrationsdaten mit GPS-Koordinaten und LiDAR-Scans ließen sich erkannte Straßenschäden zudem lokalisieren und kartieren.

Trotz der positiven Ergebnisse dieser Studie bieten sich mehrere Verbesserungspotenziale und Erweiterungsmöglichkeiten für zukünftige Arbeiten an. Momentan erkennt der Algorithmus Beschleunigungsspitzen (Peaks) mithilfe von IMU-Daten. Eine vielversprechende Weiterentwicklung wäre der Einsatz von maschinellen Lernverfahren, um sowohl die Höhe als auch weitere Merkmale dieser Peaks noch präziser zu bestimmen. Ein entsprechend trainiertes Modell

könnte dabei subtilere Muster erkennen und so verschiedene Arten von Straßenschäden besser voneinander unterscheiden (Bhoraskar et al., 2012), (Buza et al., 2013).

Ein wichtiger Faktor, der künftig in die Analysen einfließen sollte, ist das Gesamtgewicht aus Fahrrad und FahrerIn. Höheres Gewicht kann die Beschleunigungsmessungen deutlich beeinflussen und unter Umständen zu verfälschten Schlussfolgerungen über den Straßenzustand führen. Wenn diese Größen explizit berücksichtigt und eine entsprechende Kalibrierung vorgenommen wird, kann die Zuverlässigkeit der Analyseergebnisse erheblich verbessert werden (Spiric, 2014).

Auch die Geschwindigkeit, mit der man unterwegs ist, verändert die IMU-Messungen. Schnellere Fahrten führen oft zu größeren und häufigeren Schwankungen in der Beschleunigung, was die Erkennung von Straßendefekten erschweren kann. Daher ist es sinnvoll, die Geschwindigkeit systematisch in die Analyse einzubeziehen—zum Beispiel durch Geschwindigkeitskorrekturen oder indem man Daten je nach Geschwindigkeitsbereich segmentiert. Auf diese Weise lassen sich präzisere Aussagen über den Straßenzustand treffen (Sattar et al., 2018), (Seraj et al., 2016).

Literatur

Ahmed, Tufail; Pirdavani, Ali; Wets, Geert and Janssens, Davy (2024): Evaluating Bicycle Path Roughness: A Comparative Study Using Smartphone and Smart Bicycle Light Sensors. In: *Sensors* 24 (22): 7210

Bengel, Steffen (2022): Mehr Sicherheit und Komfort in der Fahrradmobilität. <https://www.iao.fraunhofer.de/de/presse-und-medien/aktuelles/mehr-sicherheit-und-komfort-in-der-fahrradmobilitaet.html>, accessed: February 12, 2025

Bhoraskar, Ravi; Vankadhara, Nagamanoj; Raman, Bhaskaran and Kulkarni, Purushottam (2012): Wolverine: Traffic and road condition estimation using smartphone sensors. 2012 Fourth International Conference on Communication Systems and Networks (COMSNETS 2012), 1–6

Buza, Emir; Omanovic, Samir and Huseinovic, Alvin (2013): Pothole Detection with Image Processing and Spectral Clustering.

Gao, Jie; Sha, Aimin; Huang, Yue; Hu, Liqun; Tong, Zheng and Jiang, Wei (2018): Evaluating the cycling comfort on urban roads based on cyclists' perception of vibration. In: *Journal of Cleaner Production* 192: 531–541

ISO 2631-1 (1997): Mechanical vibration and shock — Evaluation of human exposure to whole-body vibration. <https://www.iso.org/standard/7612.html>, accessed: February 12, 2025

ISO-8608 (2016): Mechanical vibration — Road surface profiles — Reporting of measured data. <https://www.iso.org/standard/71202.html>, accessed: February 12, 2025

Klein, Tobias (2021): Radverkehrsinfrastruktur – Baustein der Verkehrswende. Berlin

Laghbani, M.; Iliev, D.; Schwalbe, K.; Konradt, R. and Schmidt, S. (2025): OPTmicro Dataset: Open Training Data for Autonomous Microvehicles. Granada, Spain

Landratsamt Nordsachsen, Pressestelle (2023): Smart City Robots: Start für neues Fahrradverleihsystem in Schkeuditz. <https://www.landkreis-nordsachsen.de/landratsamt/aktuelles/nachrichten/artikel/smart-city-robots-start-fuer-neues-fahrradverleihsystem-in-schkeuditz>, accessed: February 12, 2025

Maeda, Hiroya; Sekimoto, Yoshihide; Seto, Toshikazu; Kashiya, Takehiro and Omata, Hiroshi (2018): Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone. In: *Computer-Aided Civil and Infrastructure Engineering* 33 (12): 1127–1141

Merz, Carina (2021): Bewertung von zwischenörtlichen Radverkehrsanlagen.

Morelli, Johannes (2022): Radverkehrsanlagen: Anforderungen an den Radverkehr und Arten von Radwegen. <https://www.forum-verlag.com/fachwissen/bau-und-gebaeudemanagement/radverkehrsanlagen-radwege/>, accessed: February 12, 2025

Oppenheim, Alan V. and Schaffer, Ronald W. (eds.) (2010): *Discrete-time signal processing*. 3. ed, Pearson, Upper Saddle River Munich

Richter, Thomas; Beyer, Oliver; Ortlepp, Jörg and Schreiber, Marcel (2019): Sicherheit und Nutzbarkeit markierter Radverkehrsführungen. 59. Gesamtverband der Deutschen Versicherungswirtschaft e.V., Berlin

Rockmore, Daniel N. (2000): The FFT: an algorithm the whole family can use. In: *Computing in Science & Engineering* 2 (1): 60–64

Saleh, DI Peter (2025): BikeStar - AIT Austrian Institute Of Technology. <https://www.ait.ac.at/en/solutions/traffic-safety/safe/bikestar>, accessed: February 3, 2025

Sattar, Shahram; Li, Songnian and Chapman, Michael (2018): Road Surface Monitoring Using

Smartphone Sensors: A Review. In: Sensors 18 (11): 3845

Schmid, Angela (2019): Dieses E-Lastenrad braucht keinen Fahrer. <https://edison.media/erleben/dieses-e-lastenrad-braucht-keinen-fahrer/23929062.html>, accessed: February 12, 2025

Schnabel, Armin; Muthmann, Dr. Klemens and Ackner, Dirk (2024): Cyface - qualitative Analyse & Erfassung von Verkehrsdaten. <https://www.cyface.de/>, accessed: February 12, 2025

Seraj, Fatjon; Van Der Zwaag, Berend Jan; Dilo, Arta; Luarasi, Tamara and Havinga, Paul (2016): RoADS: A Road Pavement Monitoring System for Anomaly Detection Using Smart Phones. In: Atzmueller, M., A. Chin, F. Janssen, I. Schweizer, C. Trattner (eds.): Big Data Analytics in the Social and Ubiquitous Context. Lecture Notes in Computer Science. 9546. Vol. Springer International Publishing, Cham: 128–146

Spiric, Goran (2014): Algorithm evaluation for road anomaly detection and wear estimation on trucks using an accelerometer. KTH Royal Institute of Technology, Stockholm, Sweden

Stork, Burkhard; Koopmann, Ludger; Kohls, Angela; Gomez, Melissa and Krone, Stephanie (2019): So geht Verkehrswende - Infrastrukturelemente für den Radverkehr. Allgemeiner Deutscher Fahrrad-Club, Berlin

VDI-2057 (2017): Einwirkung mechanischer Schwingungen auf den Menschen. Verein Deutscher Ingenieure, Düsseldorf

Wang, Xiulai; Cheng, Zhun and Ma, Ningling (2022): Road Recognition Based on Vehicle Vibration Signal and Comfortable Speed Strategy Formulation Using ISA Algorithm. In: Sensors 22 (17): 6682

Zug, Sebastian (2022): Ready For Robots. <https://ready-for-robots.de/>, accessed: February 10, 2025

Autorinnenangaben

Mahmoud Laghbani

(Korrespondierender Autor)

Wissenschaftlicher Mitarbeiter
Hochschule Merseburg
Eberhard-Leibnitz-Straße 2
06217 Merseburg,
Deutschland

E-Mail: Mahmoud.laghbani@hs-merseburg.de

Prof. Dr.-Ing. Stephan Schmidt

Professor für Mechatronische Systeme
Hochschule Merseburg
Eberhard-Leibnitz-Straße 2
06217 Merseburg,
Deutschland

E-Mail: stephan.schmidt@hs-merseburg.de

Dr.-Ing. Dimitar Iliev

Wissenschaftlicher Mitarbeiter
Hochschule Merseburg
Eberhard-Leibnitz-Straße 2
06217 Merseburg,
Deutschland

E-Mail: dimitar.iliev@hs-merseburg.de