

Schlussbericht des Verbundes

d-E-mand:

Vorhersage von Ladebedarf bei Elektromobilität als Business Enabler

Zuwendungsempfänger:	Förderkennzeichen:
Volkswagen AG, Nutzfahrzeuge, Digital Services & Data Analytics	01ME19009A
Gottfried Wilhelm Leibniz Universität Hannover, Forschungszentrum L3S Institut für Kartographie und Geoinformatik	01ME19009B
PROJEKTIONISTEN GmbH	01ME19009C
Fraunhofer-Gesellschaft zur Förderung der Angewandten Wissenschaften e.V. Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI	01ME19009D
Kontakt Konsortialführer: Dr. Nicolas Tempelmeier	Tel.: +49 511 798 894465 Email: nicolas.tempelmeier@volkswagen.de
Laufzeit des Vorhabens: von: 01.01.2020 bis: 30.06.2023	
Datum Bericht: 01.12.2023	

Inhalt

1.	Kurzdarstellung	3
1.1.	Aufgabenstellung	4
1.2.	Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	5
1.2.1.	Projektkonsortium.....	5
1.2.2.	Rechtliche Voraussetzungen	6
1.2.3.	COVID-19-Pandemie	6
1.3.	Planung und Ablauf des Vorhabens	8
1.4.	Wissenschaftlicher und technischer Stand, an den angeknüpft wurde	9
	Vorarbeiten durch das Projektkonsortium	9
	Angabe bekannter Konstruktionen, Verfahren und Schutzrechte, die für die Durchführung des Vorhabens benutzt wurden.....	11
	Angabe der verwendeten Fachliteratur sowie der benutzten Informations- und Dokumentationsdienste	11
1.5.	Zusammenarbeit mit anderen Stellen	12
2.	Eingehende Darstellung	13
2.1.	Verwendung der Zuwendung und des erzielten Ergebnisses im Einzelnen, mit Gegenüberstellung der vorgegebenen Ziele.....	13
2.1.1	Detaillierte Darstellung der Ergebnisse	20
2.2.	Wichtigste Positionen des zahlenmäßigen Nachweises	90
2.3.	Notwendigkeit und Angemessenheit der geleisteten Arbeit.....	92
2.4.	Voraussichtlicher Nutzen, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans	95
2.5.	Während der Durchführung des Vorhabens dem ZE bekannt gewordenen Fortschritts auf dem Gebiet des Vorhabens bei anderen Stellen.....	97
2.6.	Erfolgte oder geplanten Veröffentlichungen des Ergebnisses nach Nr. 11 der Nebenbestimmungen	98

1. Kurzdarstellung

Die Elektromobilität ist für die Einhaltung der globalen Klimaschutzziele alternativlos¹. Im Zuge der Elektrifizierung und Digitalisierung des Verkehrs wird zudem die Lebensqualität in urbanen Räumen steigen. Dies geschieht durch die Reduzierung von Abgasen, Lärm- und Feinstaubbelastung sowie Entlastung der Verkehrsinfrastruktur mit dem Zuwachs von E-Sharing-Angeboten wie Mobility / Transportation as a Service (MaaS / TaaS). Ab 2035 sollen in der EU nur noch emissionsfreie Autos zugelassen werden². Eine zentrale Voraussetzung für die Elektro-Mobilitätswende ist der Aufbau einer flächendeckenden Infrastruktur und digitalen Services für alle Arten von Elektrofahrzeugen. Diese Services sollen die Attraktivität der Elektromobilität durch neue Angebote steigern, und dabei die bedarfsgerechte Versorgung der Elektro-Verkehrsteilnehmer mit Strom auch bei lokalen Engpässen und erhöhtem Bedarf gewährleisten. Hierdurch kann die "Reichweitenangst" der Elektroverkehrsteilnehmer entscheidend reduziert werden.

Der Wandel hin zur Elektromobilität wird durch die Weiterentwicklungen der Batterietechnik, neue Marktteilnehmer aus dem Silicon Valley, sowie gesetzliche Rahmenbedingungen durch die EU rasant beschleunigt. So plant zur Projektbeantragung alleine die Volkswagen Gruppe 75 neue elektrische Fahrzeugmodelle bis 2029. Im Dezember 2018 waren nur rund 16.100 öffentliche und teilöffentliche Ladepunkte durch den Bundesverband der Energie- und Wasserwirtschaft (BDEW) erfasst³. Zwar befindet sich das Netz aktuell im Aufbau, jedoch ist stationäre Ladeinfrastruktur oft unzureichend um den Bedarf, insbesondere in Bezug auf Belastungsspitzen, zu decken.

Extreme Belastungen, die zum Beispiel durch den Ferienbeginn oder Großveranstaltungen verursacht werden, machen eine datenbasierte Bedarfsprognose, Planung und flexible Ladedienstleistungen unabdingbar für die optimale Versorgung der Elektromobilitätsteilnehmer. Hierdurch ergeben sich wichtige neue Geschäftsfelder im Bereich der Umgebungsdaten, Bedarfsvorhersage und der Bedienung von Belastungsspitzen, insbesondere für Kleine und Mittlere Unternehmen (KMU), sowie für Start-Ups. Genau an diesem Punkt setzte das d-E-mand Projekt an.

¹ <https://www.umweltbundesamt.de/themen/klimaschutzziele-nur-elektromobilitaet-erreichbar>

² <https://www.bmv.de/pressemitteilung/eu-mitgliedstaaten-machen-weg-fuer-emissionsfreie-pkw-ab-2035>

³ <https://www.bdew.de/presse/presseinformationen/ueber-16100-oeffentliche-ladepunkte-deutschland/>

1.1. Aufgabenstellung

Das Ziel des Projekts war die Schaffung einer Geschäftsgrundlage für KMU und Start-Ups für neuartige Dienstleistungen bezogen auf die Bedienung von erhöhtem räumlich-zeitlichen Ladebedarf von Elektrofahrzeugen und der Eröffnung neuer Geschäftsfelder in diesem Bereich. Darüber hinaus sollten für Großunternehmen, wie Netzbetreiber und Ladestationshersteller, entsprechende Analytics-Schnittstellen zur Bedarfsermittlung und Optimierung der Energieversorgung geschaffen werden. Mit den im Projekt entwickelten Lösungen sollte ein erheblicher Beitrag geleistet, um die folgenden Problemstellungen zu lösen:

Erhöhter Bedarf bei Großveranstaltungen (z.B. Messen, Events): Der durch Besucher von Veranstaltungen erhöhte Ladebedarf soll durch mobile Ladeinfrastruktur (im Weiteren "LIS") mit integriertem Batteriespeicher zur Minderung der Netzbelastung begegnet werden. Im Projekt sollten Lösungen entwickelt werden, die den aufkommenden Bedarf prognostizieren und optimale Standorte identifizieren, um den Betreibern der mobilen Ladeinfrastruktur eine wirtschaftliche Planungsgrundlage bereitzustellen.

Minderung der Netzbelastung stationärer LIS: Während des Projektstarts wurde in umfangreichen Maße Ladeinfrastruktur errichtet, um eine Flächendeckung zu erreichen. Da Netz- und LIS-Betreiber allerdings aktuell keine große Nachfrage über die nächsten Jahre erkannten, wurden (Schnell-) Ladesäulen häufig mit einer unterdimensionierten Anschlussleistung geplant, um wertvolle Netzkapazität nicht zu binden. Gerade bei Schnellladern gab es daher Bestrebungen, diese zugunsten einer geringen Anschlussleistung mit einem stationären Batteriespeicher zu ergänzen, um Ladepeaks netzdienlich abzufangen. Um die Ladevorgänge optimal im Hinblick der aktuellen Netzauslastung durch Batteriespeicher und Netzanschluss steuern zu können, benötigen LIS- und Netzbetreiber prognostizierte Ladebedarfe und -zeiten der Endkunden.

1.2. Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

1.2.1. Projektkonsortium

Das Projektkonsortium bestand aus folgenden Partnern:

Volkswagen AG

Das Projekthaus Mobile Online Dienste (MOD) von Volkswagen Nutzfahrzeuge (VWN) ist das Zentrum für Pkw-Flottendienste im Konzern und entwickelt mit ca. 200 internen und externen Mitarbeiter:innen datenbasierte Flottenlösungen für Pool- und Geschäftswagenflotten, sowie Leasing- und Importeurs-Flotten. Ride-Hailing und Ride-Sharing-Flotten rücken immer stärker in den Fokus der Entwicklung bei Volkswagen Nutzfahrzeuge und dienen dem Betrieb und der Erweiterung der bestehenden Flotten-Dienste. Das MOD-Projekthaus von VWN ist fokussiert auf Flottenthemen und verfügt über größere Datensätze aus dem Betrieb verschiedener großer Fahrzeugflotten. Neben dem Produktivbetrieb unterhält das Projekthaus auch eine eigene Entwicklungsabteilung. Im d-E-mand Projekt übernahm die Volkswagen AG mit der Marke Nutzfahrzeuge die Konsortialführung und leitete die Pilotierung in Hannover und Dresden.

Gottfried Wilhelm Leibniz Universität Hannover

Die Gottfried Wilhelm Leibniz Universität Hannover war durch zwei Institute an d-E-mand beteiligt: durch das Forschungszentrum L3S sowie durch das Institut für Kartographie und Geoinformatik.

Am **Forschungszentrum L3S** forschen ungefähr 200 Wissenschaftler:innen an Methoden für den adäquaten Umgang mit Daten und Information im Zeitalter von Internet und Digitalisierung. Zu den zentralen Forschungsthemen des L3S zählen die Extraktion der Informationen über aktuelle Ereignisse aus dem Web, sozialen Medien und Verkehrsflüssen. Als international renommiertes Forschungszentrum besitzt das L3S dabei eine langjährige Erfahrung aus zahlreichen EU-, BMBF- und DFG-Projekten sowie ERC Grants und eine hohe Kompetenz insbesondere in der Entwicklung von intelligenten Methoden unter Nutzung des Maschinellen Lernens. Im d-E-mand Projekt leitete das L3S die Entwicklung von Prognosemodellen und Algorithmen.

Das **Institut für Kartographie und Geoinformatik (IKG)** beschäftigt sich mit Grundlagenforschung im Bereich der automatischen Verarbeitung von raumbezogenen Daten. Hierzu zählen Arbeiten zur automatischen Datenintegration, -interpretation und -generalisierung, sowie zur Visualisierung und Kommunikation. Ein weiterer Schwerpunkt der Forschung am IKG ist die Erfassung räumlicher Daten. Dabei kann auf unterschiedliche Sensorik, wie z.B. Laserscanner, GPS-Geräte aber auch ein eigenes Mobile Mapping System, zurückgegriffen werden. Diese Daten bilden die Grundlage für Arbeiten, die sich mit der hochgenauen Fahrzeugpositionierung als komplementäres Verfahren zu GPS beschäftigen, bzw. zur Erzeugung hochgenauer dynamischer Umgebungskarten für autonome Fahrzeuge. Im d-E-mand Projekt leitete das IKG die Datenerfassung, Datenfusion und Analyse.

PROJEKTIONISTEN GmbH

Die PROJEKTIONISTEN GmbH kreiert maßgeschneiderte Software für digitale Geschäftsmodelle. Zu den Kunden der PROJEKTIONISTEN GmbH gehören unter anderem Dienstleistungsanbieter im Bereich Mobilität wie der GVH und die Deutsche Bahn AG, sowie die Region Hannover. Die PROJEKTIONISTEN GmbH weist ein breites Portfolio an erfolgreichen Projekten in den Bereichen Informationssysteme für ÖPNV, Visualisierung komplexer Informationen, Webauftritte und App-Entwicklung auf. Dazu gehört beispielsweise die elektronische Fahrplanauskunft des GVH, einschließlich Ticketverkauf und Nachweis am Smartphone. Auch für die Dresdner Verkehrsbetriebe AG (DVB) und den Verkehrsverbund Ober-Elbe (VVO) wurde eine Webapp und App entwickelt und kontinuierlich durch neue Komponenten erweitert. Außerdem wurde unter anderem eine App für Haltestellen und deren Umgebungen (Abfahrt.AR), eine White-Label Carsharing App und eine Taxi App entwickelt. Im d-E-mand Projekt leiteten die PROJEKTIONISTEN die Erstellung der d-E-mand Plattform sowie die Entwicklung der Anwendungen und Apps.

Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI

Das Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme (IVI) erforscht und entwickelt Technologien und Lösungen im Bereich Mobilität, Transport und Verkehr, u.a. Intelligenter Verkehrssysteme. Das IVI verfügt über langjährige Kompetenz im Entwickeln von Echtzeit-Diensten und -Anwendungen im Bereich Verkehrsdaten-Drehscheiben, Fahrzeitprognosen und Störungsinformationen. Im Rahmen des IDS leitet das IVI die Vertikalisierungsinitiative „Mobility Data Space“, um die Anwendung von Technologien zur Umsetzung von Datensouveränität auf verschiedene sensible Datenkategorien (z.B. Floating Car Data, Mobilfunk-Bewegungsdaten, Fahrzeugdaten, Mobilitätsmuster) anzuwenden und diese dadurch sicher verwertbar zu machen. In d-E-mand leitete das Fraunhofer IVI die Erfassung der Anforderungen, den Transfer und die Geschäftsmodelle.

1.2.2. Rechtliche Voraussetzungen

Die seit dem 25. Mai 2018 in den Mitgliedsstaaten der Europäischen Union direkt anwendbare Datenschutz-Grundverordnung (DSGVO) stellte für d-E-mand neben weiteren einschlägigen spezialgesetzlichen Regelungen - die wesentliche Rechtsquelle dar. Der Schutz personenbezogener Daten stellte einen wichtigen Kernpunkt dar. Die DSGVO macht zahlreiche Vorgaben zu den Voraussetzungen und Pflichten der Datenverarbeitung und zur Datenhaltung. Grundsätzlich dürfen personenbezogene Daten nur aufgrund einer gesetzlichen Ermächtigungsgrundlage verarbeitet werden (sog. Verbot mit Erlaubnisvorbehalt, vgl. Art. 6 DSGVO). Der Lösungsansatz von d-E-mand konzentrierte sich auf die Einwilligung sowie Anonymisierung der Daten als zentrale Rechtsgrundlagen zur Datenverarbeitung.

1.2.3. COVID-19-Pandemie

Aufgrund der COVID-19-Pandemie fielen viele große Veranstaltungen wie z. B. Messen aus. Die Untersuchung der temporären Erhöhung des Ladebedarfs stellte eine der wesentlichen Szenarien für d-E-mand dar. Durch den Ausfall der Veranstaltungen im Projektzeitraum lagen uns keine Daten über den lokalen Ladebedarf bei Veranstaltungen in diesem Zeitraum vor. Mit

der Wiederaufnahme von Großveranstaltungen konnten einzelne Komponenten von d-E-mand in Kontext von Großveranstaltungen evaluiert werden. Die Erstellung von Prognosemodellen für den Ladebedarf bei Veranstaltungen war aufgrund der geringen Datenlage leider nicht möglich.

Unsere Analyse und Prognose des globalen, permanenten Ladebedarfs in Städten zeigte hingegen eine höhere Komplexität als erwartet. Wir haben daher weitere Analysen für Modelle zur Vorhersage des permanenten Ladebedarfs durchgeführt, anstatt Modelle zur Vorhersage des lokalen Ladebedarfs im Kontext von Veranstaltungen zu erstellen.

1.3. Planung und Ablauf des Vorhabens

Das d-E-mand Vorhaben wurde in sieben Arbeitspaketen (APs) geplant und durchgeführt. Das vom Fraunhofer IVI geleitete AP1 beschäftigte sich mit der Anforderungsanalyse sowie mit der Entwicklung von Transferkonzepten und digitalen Geschäftsmodellen. In AP2, das vom Institut für Kartographie und Geoinformatik geleitet wurde, wurden heterogene Daten (z. B. Lidar-Daten, FLIR, Kamera, Fahrzeugsensordaten, Web-Daten, Verkehrsdaten) erfasst, fusioniert und analysiert. Weiterhin wurden Methoden der Bürgerbeteiligung entwickelt. In AP3, geleitet vom Forschungszentrum L3S, entstanden Modelle und Algorithmen für die Bedarfsprognose der Ladestationen sowie für die Reichweitschätzung und Trip-Monitoring von Elektrofahrzeugen. In AP4 wurde die d-E-mand Plattform unter Leitung von den PROJEKTIONISTEN erstellt. In AP5 wurden, ebenfalls durch die PROJEKTIONISTEN geleitet, prototypische Anwendungen erstellt. AP6 beschäftigte sich unter der Leitung von Volkswagen mit der Pilotierung der Projektergebnisse in Hannover, Dresden und in den überregionalen Szenarien. Schließlich war Volkswagen in AP7 als Querschnitts-AP für die Projektsteuerung sowie für die Koordination der Öffentlichkeitsarbeit zuständig.

Durch die COVID-19-Pandemie haben sich viele unerwartete Herausforderung hinsichtlich der Durchführung des Projektes, der Zusammenarbeit unter Pandemiebedingungen und durch den Ausfall benötigter Großveranstaltungen ergeben. Daher wurde das Projekt um sechs Monate über die ursprünglich vorgesehene Projektlaufzeit von drei Jahren verlängert.

Für das d-E-mand Projekt waren drei Meilensteine vorgesehen und erreicht, die in Tabelle 1.1 dargestellt werden. Weiterhin zeigt Abbildung 1.1 den geplanten zeitlichen Verlauf der Durchführung der Arbeitspakete als Gantt-Chart dar.

Tabelle 1.1: d-E-mand Milestones

Meilenstein	Monat	Beschreibung
MS1	M12	Initiale Plattform und Anforderungsanalyse
MS2	M24	Datenerfassung und initiale Modelle
MS3	M42	Finale Plattform und Pilotierung




Abbildung 1.1: Gantt Chart Übersicht d-E-mand Planung

1.4. Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Die Produktion von Elektroautos bis 2025 sollte laut Studien im Vergleich zur Projektbeantragung um das Zehnfache ansteigen [1]. Die steigende Anzahl an Elektroautos stellt spezifische Herausforderungen an die Lade-Infrastruktur. Diese resultierten insbesondere aus der Gleichzeitigkeit der Ladevorgänge sowie der lokalen Netzstruktur [2]. Die bis dahin entwickelten Algorithmen konzentrieren sich vorrangig auf die optimale Platzierung stationärer Ladestationen [3], [4], [5]. Die Platzierung temporären Ladestationen erfolgt unter anderen Rahmenbedingungen als die Platzierung stationärer Ladestationen. Daher wurden neue datenbasierte Algorithmen benötigt, um eine optimale bedarfsgerechte Platzierung, bzw. Dimensionierung zu prognostizieren und dynamisch zu bestimmen.

Notwendige Daten, um die lokale Nachfrage abzuschätzen, konnten dafür etwa auf freiwilliger Basis über Citizen-Science-Ansätze erhoben werden [6], bzw. aus Floating Car Data (FCD) gewonnen werden. Daten-basierte Prognosen spielten eine zunehmend wichtige Rolle um eine Vorhersage der Verkehrssituationen (z. B. typische Verkehrsauslastung, Verkehrsaufkommen bei Großveranstaltungen oder Unfallfolgen) zu ermöglichen [7]. Die dazu verwendeten Datenquellen umfassten beispielsweise Verkehrsdaten (z. B. Floating Car Data), Infrastrukturinformationen (z. B. OpenStreetMap) sowie Web-Daten (z. B. Veranstaltungskalender [8]).

Die Anwendbarkeit dieser Datenquellen für die dynamische Prognose des Ladebedarfs war bislang nicht hinreichend untersucht.

Vorarbeiten durch das Projektkonsortium

Volkswagen AG

Das Mobile Online Dienste (MOD) Projekthaus von Volkswagen Nutzfahrzeuge ist fokussiert auf Flottenthemen und verfügt über größere Datensätze aus dem Betrieb von verschiedenen Fahrzeugflotten, in denen teilweise Datenlogger verbaut worden sind. Neben dem Produktivbetrieb werden im Projekthaus auch Forschungsarbeiten durchgeführt. Die Forschungsthemen beinhalten unter anderem die Erkennung von Verkehrsfluss Anomalien, sowie dem maschinellen Klassifizieren von Fahrweisen. In dem BMWi-Projekt CampaNeo wurde in Zusammenarbeit mit dem Forschungszentrum L3S eine Plattform aufgebaut, auf welcher private und öffentliche Institutionen kampagnenbasiert und in Echtzeit Fahrzeugdaten erheben und analysieren können.

Gottfried Wilhelm Leibniz Universität Hannover

Das **Forschungszentrum L3S** an der Leibniz Universität Hannover entwickelte im BMBF-geförderten Projekt Data4UrbanMobility in Zusammenarbeit mit den PROJEKTIONISTEN datenbasierte Lösungen, die einen ereignisbasiertem Überblick über Mobilitätsinformationen in heterogenen Datenquellen unter Einbeziehung von Nutzerfeedback liefern und die effiziente Planung und Entwicklung von Mobilitätsdienstleistungen im Kontext von Großveranstaltungen ermöglichen [7] [8].

Die Verarbeitung von räumlichen und raum-zeitlichen Daten ist einer der Kernforschungsbereiche am **Institut für Kartographie und Geoinformatik** der LUH. Hier wurden Verfahren zur Interpretation räumlicher (bzw. raumzeitlicher) Daten auch hinsichtlich von Big Data Analytics entwickelt. Das beinhaltet eine Extraktion von Objekten (Fassaden, Autos, Ampeln) aus Laserpunktwolken [9], Objektinterpretation in Laserdaten [10] unter Nutzung von Deep Learning, sowie Analyse von Nutzerverhalten in Shared Spaces [11]. Schließlich wurden Ansätze realisiert, um aus kontinuierlich erhobenen Lidar-Daten dynamische Umgebungskarten (z.B. zur Parkplatzbelegung) abzuleiten [12]. Die Nutzung von Crowdsensing aus Social-Media-Daten wurde im Kontext von Starkregenereignissen untersucht [13].

PROJEKTIONISTEN GmbH

Die PROJEKTIONISTEN GmbH kreiert maßgeschneiderte Software für digitale Geschäftsmodelle. Zu den Kunden der PROJEKTIONISTEN GmbH gehören unter anderem Dienstleistungsanbieter im Bereich Mobilität wie der GVH und die Deutsche Bahn AG, sowie die Region Hannover. Die PROJEKTIONISTEN GmbH wies ein breites Portfolio an erfolgreichen Projekten in den Bereichen Informationssysteme für ÖPNV, Visualisierung komplexer Informationen, Webauftritte und App-Entwicklung auf. Dazu gehörte beispielsweise die elektronische Fahrplanauskunft des GVH, einschließlich Ticketverkauf und Nachweis am Smartphone. Auch für die Dresdner Verkehrsbetriebe AG (DVB) und den Verkehrsverbund Ober-Elbe (VVO) wurde eine Webapp und App entwickelt und kontinuierlich durch neue Komponenten erweitert. Außerdem wurde unter anderem eine App für Haltestellen und deren Umgebungen (Abfahrt.AR), eine White-Label Carsharing App und eine Taxi-App entwickelt.

Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI

Das Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI erforscht und entwickelt Technologien und Lösungen im Bereich Mobilität, Transport und Verkehr, u.a. Intelligenter Verkehrssysteme. Das IVI verfügt über langjährige Kompetenz im Entwickeln von Echtzeit-Diensten und -Anwendungen im Bereich Verkehrsdaten-Drehscheiben, Fahrzeitprognosen und Störungsinformationen. Im Rahmen des IDS leitet das IVI die Vertikalisierungsinitiative „Mobility Data Space“, um die Anwendung von Technologien zur Umsetzung von Datensouveränität auf verschiedene sensible Datenkategorien (z.B. Floating Car Data, Mobilfunk-Bewegungsdaten, Fahrzeugdaten, Mobilitätsmuster) anzuwenden und diese dadurch sicher verwertbar zu machen.

Angabe bekannter Konstruktionen, Verfahren und Schutzrechte, die für die Durchführung des Vorhabens benutzt wurden

Es wurden keine bekannten Konstruktionen, Verfahren oder Schutzrechte bei der Durchführung des Vorhabens benutzt.

Angabe der verwendeten Fachliteratur sowie der benutzten Informations- und Dokumentationsdienste

Zur fachlichen Recherche wurden gängige wissenschaftliche Informationsdienste benutzt, insbesondere Google Scholar⁴ und die Technische Informationsbibliothek⁵. Folgende Publikationen waren für d-E-mand besonders relevant:

- Mao L, Fotouhi A, Shateri N, Ewin N. A multi-mode electric vehicle range estimator based on driving pattern recognition. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science. 2022.
- Qiyu Liu, Yuxiang Zeng, Lei Chen, and Xiuwen Zheng. Social-Aware Optimal Electric Vehicle Charger Deployment on Road Network. Proceedings of the 27th ACM SIGSPATIAL. 2019.
- Zhu, Juncheng & Yang, Zhile & Guo, Yuanjun & Zhang, Jiankang & Yang, Huikun. Short-Term Load Forecasting for Electric Vehicle Charging Stations Based on Deep Learning Approaches. Applied Sciences. 2019.
- Huaxiu Yao, Yiding Liu, Ying Wei, Xianfeng Tang, and Zhenhui Li. Learning from Multiple Cities: A Meta-Learning Approach for Spatial-Temporal Prediction. In The World Wide Web Conference. 2019.

⁴ <https://scholar.google.de/>

⁵ <https://www.tib.eu/>

1.5. Zusammenarbeit mit anderen Stellen

Während der Projektlaufzeit wurden regelmäßig die Statusseminare und Netzwerktreffen des IKT für Elektromobilität Programms besucht.

Es wurde bei der Entwicklung des Trip-Monitoring-Dienstes eine Schnittstelle des Verkehrsinformationsanbieters Graphmasters⁶ genutzt.

⁶ <https://www.graphmasters.net/>

2. Eingehende Darstellung

2.1. Verwendung der Zuwendung und des erzielten Ergebnisses im Einzelnen, mit Gegenüberstellung der vorgegebenen Ziele

Die erzielten Ergebnisse werden zunächst pro Partner kompakt in Tabelle 2.1, Tabelle 2.2., Tabelle 2.3 und Tabelle 2.4 zusammengefasst. Danach werden alle aufgeführten Ergebnisse einzeln in Textform detailliert.

Tabelle 2.1: Verwendung Teilvorhaben Volkswagen AG

Geplantes Ergebnis	Verwendung der Zuwendung	Erzieltes Ergebnis
R1.2 Transferkonzept	Personal zur Erfassung der relevanten Komponenten und Koordination der Konzepterstellung.	Transferkonzept inklusive Risikostrategien das transferierbare Komponenten wie kategorisiert: <i>Soziales Engagement, Öffentlichkeitsarbeit, Kommerzialisierungsmöglichkeiten</i>
R2.3 Erfassung und Analyse der Fahrzeugsensordaten	Personalkosten zur Planung und Durchführung der Datenerfassung sowie Entwicklung der Algorithmen.	Routenplanung und Softwarekomponenten zur DSGVO-konformen Datenvorverarbeitung, Segmentierung und Analyse zur E-Fahrzeuwerkerkennung
R2.6 Hardware Sensoraufbau TAAS/MAAS	Personalkosten zur Auswahl, Beschaffung und Konstruktion des Sensoraufbaus. Materialkosten zur Beschaffung der Sensoren.	Sensoraufbau für Datenfahrrad mit Lidar, RGB-Kameras, Thermalkamera und GPS-Sensor
R6.1.1 Trainingsmaterial für die Pilotierung in Hannover	Personal zur Bewertung der Use-Cases und zur Erstellung des Trainingsmaterials.	Bewertungsmatrix für Use-Cases und Trainingsmaterial zur Pilotierung in Hannover
R6.1.2 Ergebnisse der Pilotierung in Hannover	Personal zur Durchführung der Pilotierung und Auswertung der Ergebnisse.	Pilotierungsergebnisse als qualitative Inhaltsanalyse
R7.2.1 Onlinepräsenz	Personal zur Abstimmung der Inhalte der d-E-mand Website	d-E-mand Website, https://www.d-e-mand.org
R7.2.2 Bericht Öffentlichkeitsarbeit	Personal zur Durchführung und Koordination der Öffentlichkeitsarbeit	17 wissenschaftliche Publikationen, Vorstellung von d-E-mand auf relevanten Fachkonferenzen und Netzwerktreffen

Tabelle 2.2: Verwendung Teilvorhaben Gottfried Wilhelm Leibniz Universität Hannover

Geplantes Ergebnis	Verwendung der Zuwendung	Erzieltes Ergebnis
R2.1 Datenkatalog	Personal zur Erstellung des Datenkatalogs und Koordination der Datenkategorisierung.	• Datenkatalog wurde erstellt. • Pilotgebiete wurden definiert. • Daten wurden für Projektpartner verfügbar gemacht. • Webbasierte Visualisierung wurde erstellt.
R2.2.1 Erfassung und skalierbare Datenfusion	Personal zur Auswahl und Einrichtung eines Servers. Materialkosten zur Beschaffung des Servers.	Beschaffung und Einrichtung eines geeigneten Servers zur Verarbeitung von Laserscanner-Punktwolken. Erfassungsplan für Messfahrten.
R2.2.2 Analyse der Lidar-Daten	Personal zur Entwicklung der Pipeline und der Algorithmen.	Pipeline zur Verarbeitung von Lidar- / Laserscanner-Daten. Algorithmus zur Identifikation von Fahrzeuginstanzen.
R2.4 Erfassung und Analyse der Web- und Verkehrsdaten	Personal zur Beschaffung und Analyse der Daten. Materialkosten zur Beschaffung der Verkehrsdaten.	Sammlung und Analyse von Daten aus den Bereichen Web und Verkehr insbesondere Floating Car-Daten, Fahrzeugzulassungsdaten, Ladestation-Daten, Veranstaltungsdaten und Geo-Daten
R2.5 Methoden der Bürgerbeteiligung	Personal zur Konzeption der Anwendungsfälle und Durchführung einer Nutzerstudie.	Konzept für Anwendungsfälle, qualitative Ergebnisse einer Nutzerstudie
R3.1 d-E-mand Datenmodell	Personal zur Entwicklung des Datenmodells.	Es wurde ein Datenmodell und ein Integrationsframework entwickelt, das verschiedene Datenquellen integriert.

R3.2 Prognosemodelle für mobile und stationäre LIS	Personal zur Entwicklung der Algorithmen	Entwicklung von Modellen insbesondere zur Vorhersage der Ladeauslastung, zum Wissenstransfer zwischen Städten, zur Reinforcement Learning-basierten Platzierung von Ladesäulen, zur Erkennung von möglichen LIS-Standorten aus Lidar-Daten und zur Web-basierten Visualisierung
--	--	---

Tabelle 2.3: Verwendung Teilvorhaben PROJEKTIONISTEN GmbH

Geplantes Ergebnis	Verwendung der Zuwendung	Erzieltes Ergebnis
R1.3 Digitale Geschäftsmodelle	Personal zur Analyse bewährter digitaler Geschäftsmodelle und Erarbeitung neuer für das Projekt geeigneter Geschäftsmodelle	Digitale Geschäftsmodelle für: • mobile Anwendung (App) für E-Mobilisten (B2C) • eine B2B-Plattform, die für Veranstaltende und Betreibende von mobiler Ladeinfrastruktur (LIS-Betreibende) gedacht ist
R4.1 Plattformkonzept	Personal zur Durchführung der technischen Konzeption einer dezentralen Architektur für die d-E-mand Plattform.	Detailliertes Plattformkonzept zur Umsetzung der d-E-mand Plattform mit Berücksichtigung der iterativen und agilen Entwicklung.
R4.2 Plattform-Release	Personal zur Implementierung der d-E-mand Plattform nach agilen Vorgehensmodellen und Erstellung einer <i>continuous integration</i> (CI) Pipeline für die verschiedenen Pilotierungs-Modi.	d-E-mand Plattform • CI-Pipe • containerbasierte Umsetzung • Umsetzung mit Cloud-Technologie, um eine Skalierbarkeit zu implementieren • Integration des User- und Rollenkonzepts • Nutzung der cloudbasierten Gateways • Prototypische Umsetzung der d-E-mand B2C-App (Client-Anwendung) Prototypische Umsetzung der d-E-mand B2B-Anwendung (Integrierte Anwendung für LIS-Betreibende und Veranstaltende)
R4.3 API und Microservices	Personal zur Implementierung der nötigen Funktionen der d-E-mand Plattform als API (graphql, REST) für die Anbindung von Anwendungen.	• Umsetzung der API für den Anschluss von Apps • Umsetzung eines Matching Algorithmus für Routing mit inkludierter LIS • Umsetzung einer Meta Routing Integration (Intermodales Routing)

R5.1 Dashboard für Planung der E-Mobilitätsservices	Personal zur Durchführung einer Anforderungsanalyse und Implementierung des Dashboards.	d-E-mand Dashboard (B2B-Anwendung) • Zielgruppenorientierten Konzeption des UX/UI • Responsiver Dashboard-Rahmen • Interaktive modulare Komponenten • Nutzerzentriertes Bedienkonzept
R5.2 Apps für E-Verkehrsteilnehmer - Finale Version	Personal zur zielgruppenorientierten Konzeption des UX/UI und Implementierung einer hybriden App.	d-E-mand App (B2C-Anwendung) • Zielgruppenorientierten Konzeption des UX/UI • Hybrider App Rahmen • Integration von modularen Komponenten zur Visualisierung und Bürgerbeteiligung • Nutzerzentriertes Bedienkonzept

Tabelle 2.4: Verwendung Teilvorhaben Fraunhofer IVI

Geplantes Ergebnis	Verwendung der Zuwendung	Erzieltes Ergebnis
R1.1 Ergebnisse der Zielgruppendefinition, Geschäftsideen und Anforderungssammlung	Personal zur Definition und Analysen der durch die Plattform zu unterstützenden Use-Cases, Business Cases und Prozesse sowie von Geschäftsmodell-Ideen.	Spezifizierte Use Cases und Definition von Rollen. <i>(Siehe Abbildung 2.2 Anforderungsanalyse für d-E-mand Plattform Abbildung 2.2)</i>
R1.1 Anforderungsanalyse für d-E-mand Plattform	Personal zur Ableitung der funktionalen Anforderungen und nicht-funktionale Anforderung.	Use Case Requirements Spezifikation pro Use Case <i>(Siehe Abbildung 2.1 Beispielhafter Use-Case aus Anforderungsanalyse)</i>
R3.3 Reichweitenschätzung	Personal zur Entwicklung eines Services für eine kontextabhängige Reichweitenschätzung und Anbindung der benötigten Datenbanken und entsprechender Module.	Prototyp eines Services für eine kontextabhängige Reichweitenschätzung, welche die verbleibende Reichweite für ein batterieelektrisches Fahrzeug berechnet und als Reichweitenprognose ausgibt.
R3.4 Trip-Monitoring	Personal zur Entwicklung des Services und Anbindung des Services an den Message Broker RabbitMQ sowie weiteren Diensten.	Prototyp eines Services zur Überwachung von geplanten Fahrten, die zum Beispiel von einer LIS-Navigation eingestellt werden. Eine Fahrt wird überwacht bezüglich Verzögerungen, Restreichweite sowie Verkehrslage.
R4.4 IDS-Connectoren	Personal zur Arbeit an einer IDS-kompatiblen Connector-Implementierung.	Der entwickelte Connector steht nun als Open Source zur Verfügung und kann in nachfolgenden Projekten eingesetzt werden.

R4.5 Verknüpfung mit weiteren Datenplattformen	Personal, um Anbindungen an die MDM-Plattform zu erproben und dort Straßenverkehrsdaten abzurufen sowie sich mit Teilnehmern des Mobility Data Spaces zu verbinden.	Integrationskonzept zur Verknüpfung mit weiteren IDS-fähigen Datenplattformen, um Datenangebote dieser Plattformen in d-E-mand integrieren und nutzen, sowie die Ergebnisse von d-E-mand auf diesen Plattformen anbieten zu können
R6.2 Trainingsmaterial für die Pilotierung in Dresden	Personal zur Planung der Pilotierung und Durchführung 25 Testfahrten.	Eine Herangehensweise und ein Setting, um Testfahrten zu monitoren und die Logs der Dienste auszuwerten. Ein System um die in realen Testszenarien erhaltenen Testdaten weiter als synthetische Daten für weitere Simulationen nutzen zu können.
R6.2 Ergebnisse der Pilotierung in Dresden	Personal zur Pilotierung und Evaluation der Trip Monitoring und RangeEstimation Services beim Einsatz im Fahrzeug auf der Straße in und um Dresden. Die Services wurden über die LIS-Navigation angesprochen, die geplanten Strecken wurden gefahren und nachfolgend wurden die Logs der Services ausgewertet.	Graphische Darstellungen der einzelnen Testfahrten mit Anzeige der Verzögerungen, Ladezustand und ausgegebenen Benachrichtigungen und Lessons Learned.

2.1.1 Detaillierte Darstellung der Ergebnisse

R1.1 Anforderungsanalyse

Im Arbeitspaket 1 wurden die Definitionen und Analysen der durch die Plattform zu unterstützenden Use-Cases und Business Cases und Prozesse durch Anwendungspartner umgesetzt. Daraus folgten Ableitung (AP 1.1) erster funktionaler Anforderungen (APIs & Anwendungsfunktionalitäten) und nicht-funktionale Anforderungen (Benutzbarkeit, Skalierbarkeit, Performanz, etc.) sowie erster Geschäftsmodell-Ideen (AP 1.3). Abbildung 2.1 zeigt einen beispielhaften Use-Case mit zugehörigen Anforderungen, während Abbildung 2.2 die Anforderungsanalyse für die d-E-mand Plattform zusammenfasst.

UC5: Informieren über (mobile) LIS-Verfügbarkeiten

Erstellt von Nicolas Tempelmeier am Sep 01, 2020

Business		Need	Solution	
Product Owner <i>Who is responsible for controlling the scope of the solution and ensuring that it provides value to the organisation as a whole?</i> LUH/L3S	Activities <i>What activities do the stakeholders perform and what goals do they achieve by performing these activities?</i> The EV customer queries the mobile application to get information about available charging capacities. The EV customer can also use routing to reach the best charging stations. The EV customer can access information about the availability of charging capacities in the near future. The goal of the EV customer is to charge his car as convenient as possible. The EV provider wants to provide a convenient charging process. The goal of the EV provider is to bind the customer.	Strategic <i>Which strengths need to be built on or preserved, weaknesses remedied, opportunities exploited, and/or threads avoided?</i> <i>Strengths:</i> - Usable app - Comprehensive map of stations - Working predictions	Features <i>How can the solution satisfy a need by implementing a capability such as storing and retrieve data, interact with users, interfacing with other systems and/or devices, or enforcing a rule?</i> <i>How should individual features or the entire solution be constrained?</i> Retrieve stations Retrieve occupied stations Retrieve station load prediction Display map to the user Provide recommendation for the user Rate charging station	Vision <i>Who is the target customer for the solution?</i> EV customers who are generally open-minded towards new technology- <i>What is the customer's major operational strategic need?</i> The customer needs to charge his car. <i>What is the key benefit of compelling reason to acquire the solution?</i> It is easier to find a charging station compared to other solutions. <i>How does the solution differ from competing solutions or practices?</i> Available predictions Possibility to rate stations
Subject Matter Experts <i>Who possesses expert knowledge of the problem domain or some aspect of the solution?</i> - VW - Fraunhofer - LUH - IKG - L3S - PROJ		Information <i>What information needs to be stored, retrieved and manipulated?</i> Map of charging stations Charging load prediction Charging stations rating		Interfaces <i>What are the major user interfaces and APIs provided by the solution?</i> The user interface as mobile app (Dashboard ?) Data API
Other Stakeholders <i>Who else is involved (need to comply, need to consult, need to inform, need to restrict flow of information)?</i> - EV customer - EV provider		Rules <i>What aspects of the problem domain need to be defined, constrained or guided in some way?</i> Rating of stations should be constrained		Components <i>What are the major components of the solution?</i> Mobile application Station database Prediction model

Abbildung 2.1 Beispielhafter Use-Case aus Anforderungsanalyse

T1.1 Anforderungsanalyse für d-E-mand Plattform

Erstellt von Timo Graen, zuletzt geändert von Sebastian Pätzsch vor Kurzem

Use Case Übersicht (als Diskussionsgrundlage)

Use Case Nr	Use Case Name	Zielgruppe (Kunde/Endnutzer)	Kurzbeschreibung (inkl. Relation der Stakeholder und ggf. erster Geschäftsidee)	Use Case Owner (wer kümmert sich?)	Priorität (1-3)	Kommentare / Anmerkungen
B2B Use Cases						
1	Bedarfsmittlung / Kapazitätsplanung für Veranstalter	- Betreiber von mobiler LIS - Veranstalter (Kunden von Betreiber von mobiler LIS)	Ein Veranstalter möchte für eine Veranstaltung (Messe, Konzert, Sportevent) für seine Besucher mobile Ladeinfrastruktur anbieten. Anhand von Daten über Besucher (durch Buchung, durch Befragung, durch Beobachtung) ist dem Veranstalter die Menge und ein grobes Nutzerprofil bekannt. <i>Alternative A:</i> Der Veranstalter nutzt eine Anwendung der d-E-mand-Plattform, um den mobilen LIS-Bedarf zu ermitteln und ggfs. bei einem Betreiber mobiler LIS zu buchen. <i>Alternative B:</i> Der Betreiber mobiler LIS bietet dem Veranstalter die Bedarfsmittlung/Kapazitätsplanung auf Basis anonymisierter Besucherdaten als Dienstleistung an. Der Betreiber mobiler LIS nutzt dazu eine Anwendung der d-E-mand-Plattform. Der Veranstalter informiert den Besucher mit EV über die LIS-Verfügbarkeit (Anknüpfung an Use Case 5).	L3S	1	Eventuell unterscheiden: Der Konzertveranstalter hat andere Anforderungen als ein Messe-Veranstalter
2	Optimale Standort- und Kapazitätsplanung im (öffentlichen) Straßenraum	Betreiber von mobiler LIS (lonity)	<i>Alternative A (B2C):</i> Der Betreiber mobiler LIS möchte den Endkunden-Bedarf im Straßenverkehr (z.B. bei Ferienverkehr) bestmöglich bedienen. Über eine Anwendung der d-E-mand Plattform informiert er sich über erhöhtes Reiseaufkommen und optimale Standorte, um den daraus resultierenden Bedarf durch mobile LIS abzudecken. Der Bedarf kann der d-E-mand Plattform u.a. vom EV-Flottenbetreiber (z.B. VW) gemeldet werden, da er ein gutes Kundenverständnis hat (z.B. über Routing- und Navigationsinformationen; siehe Use Case 4). <i>Alternative B (B2B):</i> Der EV-Flottenbetreiber (VW) bietet dem Endkunden ein Service-Paket an, in dem die flächendeckende Nutzung von LIS enthalten ist. Um die Qualität dieser Dienstleistung sicherzustellen, beauftragt der EV-Flottenbetreiber den Betreiber mobiler LIS um die flächige Aufstockung nach Bedarf (zielerichtet nach den Bedarfen der eigenen Kunden).	IKG/VW	1	
3	temporäre Kapazitätserweiterung stationärer LIS im (öffentlichen) Straßenraum	- Betreiber von mobiler LIS - Betreiber stationärer LIS (BS Energy) - Netzbetreiber	Betreiber stationärer LIS sind bei bestimmten Ereignissen mit erhöhter Nachfrage konfrontiert, die die vorhandene stationäre LIS nicht abdecken kann. Eine Anwendung der d-E-mand Plattform informiert den Betreiber stationärer LIS über Zeitpunkt und Bedarf der erhöhten Nachfrage. Der Betreiber stationärer LIS bucht beim Betreiber mobiler LIS weitere temporäre Kapazität dazu <i>(In diesem Use Case spielt der Netzbetreiber eventuell auch eine Rolle)</i>	PROJ	2	
B2C Use Cases						
4	Informieren über Verkehrslage und Restreichweite	EV Nutzer	Die Fahrt der EV-Nutzer wird durch einen Trip-Monitoring Service im Hinblick auf Reichweite-reduzierende Ereignisse (z.B. Stau durch Reiseerlen) gemonitort. Die Fahrt ist durch eine Navigationsanwendung bekannt, die entweder im Fahrzeug VW Infotainmentsystem oder in einer dedizierten Smartphone-App (PROJ) durch den Nutzer eingegeben wurde. Basierend auf der aktuellen Verkehrslage, auftretenden Echtzeit-Ereignissen (Staus, Straßensperrungen, Unfälle) und Informationen über die aktuelle Restreichweite berechnet das Trip-Monitoring (Fraunhofer IVI) Hinweismeldungen für den EV Nutzer, falls die aktuelle Route eingeschränkt ist, sich die Fahrt deutlich verlängert oder das Ziel durch eine sinkende Restreichweite nicht mehr erreicht werden kann. Per Hinweismeldungen über das VW Infotainmentsystem/Navigations-Smartphone-App der Projektionisten (evtl. auch Kombination aus Infotainment + App) kann über notwendige (Nach-)Ladungen an (mobilen) Ladesäulen entlang der Strecke informiert/reserviert werden (Siehe Use Cases 5, 6 und 7). <i>Mögliche B2B-Erweiterung:</i> Die Hinweismeldungen werden nicht nur an den EV Nutzer, sondern auch an den Flottenbetreiber/Fuhrpark Manager (z.B. über VW Connect Fleet) per API bereitgestellt, der diese Informationen in seine Geschäftsprozesse integrieren kann (Tourenplanung, Supplychain Management usw.).	Vorschlag: VW (VW/PROJ)	1	👤Timo Graen: 19.06.2020 bitte die B2B-Variante prüfen
5	Informieren über (mobile) LIS-Verfügbarkeiten	EV Nutzer	Der EV-Nutzer verfügt über eine dedizierte Smartphone-App (Navigations-Smartphone-App der Projektionisten), die die Position von (mobilen) Ladestation auf einer Karte anzeigt. Weiterhin wird dem EV-Nutzer nach Möglichkeit die Verfügbarkeit der Ladestation mitgeteilt. Basierend auf historischen Daten werden auch Prognosen zur Verfügbarkeit der LIS angezeigt. Es werden Empfehlungen ausgesprochen, zu welchem Zeitpunkt am Besten unter Berücksichtigung von Preis und Verfügbarkeit geladen werden kann. Kann sich bei Bedarf zur LIS navigieren lassen. Weiterhin kann er defekte LIS melden und vorhandene LIS bewerten.	Vorschlag: L3S (PROJ)	1	Hinweis: Das Thema Bürgerbeteiligung (siehe GVB) sollte in einem der UC 5-7 auftauchen B2C Use Case - 5,6,7,10 stehen in Beziehung/ Abhängigkeit zueinander
6	Vorbehaltlich Klärung mit BS Energy: Reservierung von Lademöglichkeiten	- EV Nutzer - Betreiber von (mobiler) LIS (z.B. BS Energy)	Der EV-Nutzer verfügt über eine dedizierte Smartphone-App und möchte darüber eine ausgewählten LIS reservieren können. Über ein Routing-System kann er nun zu seiner reservierten LIS navigiert werden.	Vorschlag: PROJ	TODO	👤Tim Seidler // PROJEKTIONISTEN: bitte mit BS Energy prüfen, ob es eine Reservierungsfunktion in deren Backendsystemen gibt - Anfrage abgeschickt - 19.06.2020 - 11.00Uhr - Antwort erhalten - 22.06.2020 - 9:49Uhr: - Hario Herr Seidler, eine Reservierungsfunktion bzw. eine Schnittstelle hierzu konnten wir in unserem Backend nicht finden. Diese Funktion würden wir für den praktischen Betrieb auch nicht unbedingt vorsehen wollen (oder wenn, dann mit Kostenpauschale), da wir ansonsten eine dauerhaft hohe Reservierungsquote unserer Ladesäulen befürchten würden. Beste Grüße Lennart Schümann KOM/DIA Projektmanager Innovation - Elektromobilität Telefon 0531 383 2270 lennart.schumann@kom-dia.de
7	Anmeldung zu Events mit Bedarf von E-Ladung	- EV Nutzer - Betreiber von (mobiler) LIS - Veranstalter	Routing von A nach B geschicktes VIA-Routing zu möglichen freien LIS oder anderer POI - ggf. auch mit höherer Distanz zum Veranstaltungsort, wenn Erreichbarkeit der Veranstaltung mit "organisiert" wird - ggf. Ermittlung von erhöhtem Bedarf und automatisierter Organisation von dynamischen LIS (Vermittlung an Transporteure und Besitzern von dyn. E-Ladesystemen → evtl. eigener B2B-UseCase) - zeitlicher Voraufruf ggf. später Vorhersagen, um schon den Bedarf abzuschätzen nahtloses Routing zur Veranstaltung und zurück (Beratung/Entscheidung von ÖPNV, Micro-Mobilität, Mitfahrgelegenheit, Ride-Sharing, etc.) Mobilitätsgarantie	Vorschlag: PROJ	TODO	👤Tim Seidler // PROJEKTIONISTEN: Bitte prüfen auf Überschneidung mit vorherigen Use Cases (i.a. 4); bitte davon abgrenzen oder mit diesen vereinen → Aus Nutzersicht differenziert zu betrachten: - ggf. andere Zielgruppe - Abgrenzung zu UC 4: bei UC 4 handelt sich um eine ad-hoc-Funktion (ad-hoc-Forecast während Fahrt); bei UC 7 um einen Anwendungsfall hinsichtlich der Planung eines Events (Forecast über vorhandene LIS-Infrastruktur zu einem bestimmten Event)

Abbildung 2.2 Anforderungsanalyse für d-E-mand Plattform

R1.2 Transferkonzept

Ziel dieser Aufgabe war es technische und nicht-technische Projekt (Teil-)Ergebnisse zu identifizieren, die einem weiteren Nutzen zugeführt werden können und in einem Transferkonzept zusammenzufassen. Um die Güte der transferierten Ergebnisse aufrechtzuerhalten und die Wahrscheinlichkeiten für einen Fehlschlag, bei der Umsetzung, zu minimieren wurde ebenfalls eine an das Transferkonzept angelehnte Risikostrategie entworfen. Nach der Identifizierung der transferierbaren Projektergebnisse mit Absprache der Projektpartnern wurde die reale Umsetzbarkeit mit assoziierten Projektpartnern besprochen. Dabei wurde die initiale Version des Transferkonzepts erweitert/gekürzt und geschärft.

Das resultierende Konzept wurde tabellarisch strukturiert, und in ein Transferkonzept und eine Risikostrategie unterteilt. Es wurden insgesamt 21 Projekt (Teil-)Ergebnisse identifiziert, die für grundsätzlich einen Transfer in Frage kommen. Bei der Erstellung der Transferkonzepte wurden die folgenden Drei Kategorien berücksichtigt:

- Soziales Engagement
- Öffentlichkeitsarbeit
- Kommerzialisierungsmöglichkeiten

Neben der Transferstrategie wurde zu jedem Konzept der Leiter sowie deren Verantwortliche identifiziert. Unter Zuhilfenahme des Gantt-Charts zum Projektablauf wurde der früheste Ausführungszeitraum der Konzepte bestimmt. Weiterhin wurde in enger Abstimmung mit den Projektpartner die tatsächliche Realisierbarkeit der Ergebnisse auf einer Skala bewertet, um einen Eindruck über die Komplexität der Umsetzbarkeit zu erhalten.

Weiterhin wurden alle Ergebnisse mit Bezug auf Umsetzungszeitpunkt und Realisierbarkeit bewertet. Insgesamt wurde 30 Risiken einschließlich möglicher Gegenmaßnahmen identifiziert. Für die Erstellung wurde vorab das individuelle Risiko analysiert, welches von den transferierbaren Projektergebnissen ausgeht. Dabei werden Risiken in zwei Kategorien unterteilt:

- Technische
- Nicht-technische

Unter Gefahren der ersten Kategorie fallen Probleme, die im Zusammenhang mit Software oder Hardware stehen. Nicht-technische Risiken beinhalten unter anderen rechtlichen Hürden. Schließlich wurden alle Risiken mit Hinsicht auf die erwartete Eintrittswahrscheinlichkeit bewertet. Die relevantesten Ergebnisse werden in Abschnitt 2.4 Voraussichtlicher Nutzen beschrieben.

R1.3 Digitale Geschäftsmodelle

Im Laufe des Projektes wurden sowohl eine mobile Anwendung (App) für E-Mobilisten (B2C) als auch eine B2B-Plattform, die für Veranstaltende und Betreibende von mobiler Ladeinfrastruktur (LIS-Betreibende) gedacht ist, entwickelt.

Zur späteren Weiterentwicklung dieser Anwendungen und Systeme wurde je ein Geschäftsmodell in Form eines Business Model Canvas erarbeitet.

Business Model Canvas B2C

Für das Geschäftsmodell der B2C-App wurden drei verschiedene Kundengruppen herausgearbeitet:

- Besitzer von Elektroautos,
- Besucher von Veranstaltungen, die Elektroautos fahren,
- Flottenbetreiber (u.a. Carsharing Anbieter).

Alle Gruppen haben dabei gemeinsam, dass sie mittels einer App eine gezielte Routennavigation erhalten möchten, die berücksichtigt, dass Elektroautos in bestimmten Abständen an Standorte von mobiler Ladeinfrastruktur navigiert werden müssen. Dies soll außerdem zeitlich in die Routenberechnung mit einfließen. Außerdem bietet es den Nutzenden einen Mehrwert, wenn Fahrtpausen optimal genutzt werden (z.B. während einer Veranstaltung), sodass das Fahrzeug in dieser Zeit wieder geladen und so anschließend wieder mehr Reichweite erzielt werden kann.

Um daraus Ertrag zu erzielen, ist es denkbar, dass beispielsweise eine Premium-App-Nutzung angeboten wird. Außerdem könnte Ertrag erzielt werden, indem Provision für die angesteuerte LIS erhoben oder die Generierung von Daten genutzt wird.

Das ausführliche Business Model Canvas ist in Abbildung 2.3 zu sehen.

Business Model Canvas B2B

Veranstaltende und LIS-Betreibende stehen bereits heute in Kontakt, um das Angebot von mobiler Ladestruktur bei Veranstaltungen zu planen und für die Besucher einer Veranstaltung entsprechend bereitzustellen. Um diesen Kontakt möglichst einfach, zeitsparend und effizient zu gestalten, wurde die B2B-Plattform entwickelt.

Eine solche Plattform gibt es in der Art noch nicht auf dem Markt, sodass diese die Bedürfnisse der Zielgruppen nach Vereinfachung ihrer Arbeit erfüllen kann.

Die Plattform wurde nutzendenzentriert konzipiert und ist dadurch schnell in der Bedienung zu erlernen und zu nutzen. Durch die Beachtung der konkreten Arbeitsschritte kann sie Anfragen von Veranstaltenden an LIS-Betreibende organisieren und datenbasierte Empfehlungen für LIS liefern.

Aufgrund des hohen Mehrwerts der Plattform sind verschiedene Ertragsquellen denkbar. Dazu zählen unter anderem eine Vermittlungsgebühr, die Veranstaltende zahlen, wenn ein Vertrag mit einem LIS-Betreibenden zustande kommt oder auch die Nutzung eines Freemium-Modells der Plattform.

Die weiteren Ertragsquellen und das gesamte Business Model Canvas sind in Abbildung 2.4 detailliert dargestellt.




Abbildung 2.3 Business Model Canvas B2C




Abbildung 2.4 Business Model Canvas B2B

R2.1 Datenkatalog

Erstellung des semantischen Datenkatalogs

Basierend auf den Ergebnissen der Anforderungsanalyse wurden die relevanten Daten und Datenquellen ermittelt. Im Detail wurden hierbei anwendungsfall-relevante Objekte identifiziert, beschrieben und deren Verfügbarkeit in den bereits existierenden Datenquellen überprüft. Zudem wurden ebenfalls relevante Verkehrs- und Webdaten sowie deren Quellen identifiziert. Zur Strukturierung und Bereitstellung dieser Daten für die Projektpartner wurde ein semantischer Datenkatalog erstellt. Dieser Katalog enthält Meta-Informationen zu den Datensätzen, die eine umfassende Beschreibung der verfügbaren Daten bieten und somit eine effiziente Zusammenarbeit mit diesen Daten ermöglichen. Der Datenkatalog besitzt die folgende Struktur:

- *Datensatz A*
 - *Allgemeine Beschreibung Datenquelle/-satz*
 - *Räumliche und zeitliche Ausdehnung*
 - *Zugriff*
 - *Beschreibung der relevanten Entitäten/Features*
 - *Attribute*
 - *Ausprägungen*
 - *Visualisierung*
- *Datensatz B*
 - ...

Tabelle 2.5 gibt einen Überblick über die enthaltenen Datensätze geordnet nach Datenquelle.

Tabelle 2.5 Übersicht über die Datensätze im Datenkatalog

OpenStreetMap (OSM)	
	<i>Straßen-/Wegenetz</i>
	<i>Gebäude</i>
	<i>Points of Interest (POIs)</i>
Laserscan-3D-Punktwolken	
	<i>Statische Objekte (Gebäude, Infrastruktur, Vegetation)</i>
	<i>Dynamische Objekte (Fahrzeuge, Fußgänger)</i>
Floating Car Data von INRIX	
	<i>Meta-Informationen zu den Trajektorien</i>
	<i>Wegpunkte der Trajektorien</i>
TOMTOM APIs	
	<i>LIS</i>
	<i>LIS-Zustände</i>
Veranstaltungsdaten	
	<i>Veranstaltungen</i>
LIS-Daten	
	<i>LIS-Standorte</i>

	LIS-Auslastung
Verwaltung	
	KFZ-Zulassungsdaten
	...

Erstellung einer webbasierten Visualisierung

Zur Verfügbarmachung der erhobenen räumlichen und raumzeitlichen Daten innerhalb des Projektkonsortiums wurde eine GeoServer-Instanz eingerichtet und gehostet. Diese ermöglicht den Abruf der Daten gebündelt nach Thema (Datenlayer) in verschiedenen Datenformaten und Koordinatensystemen. Gleichzeitig wurde eine webbasierte Visualisierung der Daten implementiert. Die Web-Karte „d-E-mand Data Web Viewer“ ermöglicht so einen schnellen Überblick über die räumliche Verteilung der Daten, insbesondere in den zuvor definierten Pilotgebieten. Mit Hilfe einer Benutzerschnittstelle lassen sich die folgenden Datenlayer ein- und ausblenden:

- Pilotregionen
- Stationäre Ladesäulen (verschiedene Quellen, nicht integriert)
- Parkplätze/-häuser (OpenStreetMap)
- Veranstaltungen (L3S-Veranstaltungskatalog)
- Laserscan-Punktwolken
- Parkflächen entlang Straßen

Abbildung 2.5 zeigt einen Ausschnitt des d-E-mand Data Web Viewers.




Abbildung 2.5: d-E-mand Data Web Viewer ermöglicht einen schnellen Überblick über die verschiedenen Daten und deren räumlicher Verteilung

Definition der Pilotgebiete

Die Pilotgebiete wurden zusammen mit den Projektpartnern definiert. Um die Herausforderungen, die in diesem Projekt angegangen werden sollten, gut abzubilden, wurde hierbei darauf geachtet, dass die Gebiete die folgenden Aspekte beinhalten:

- eine Kombination von Wohn-, Industrie- und Innenstadtgebiet
- typische Veranstaltungsorte (Stadion, Konzerthalle, usw.)
- unterschiedliche Parkmöglichkeiten (öffentliche Parkplätze, Park & Ride-Plätze, usw.)
- stationäre Ladeinfrastruktur

Abbildung 2.6 zeigt die ausgewählten Gebiete innerhalb der Region Hannover. Das links unten dargestellte, größere Teilgebiet erfüllt sämtliche der obigen geschilderten Anforderungen, lässt sich aber dennoch innerhalb eines Tages erfassen. Das kleinere Gebiet rechts unten weist nicht alle Anforderungen auf, zeichnet sich aber durch eine dichte Bebauung und damit einhergehend hohen Parkdruck aus. Die Dimension dieses Gebiets ist so gewählt, dass es sich mehrfach am Tag erfassen lässt und somit auch eine gewisse zeitliche Dynamik erfasst werden kann. Die Gebiete in rechts oben und links oben wurden im späteren Projektverlauf aufgenommen. Dabei handelte es sich um die Erfassung der Straßenräume und Parkflächen während zwei Großereignissen (Hannover Messe, Bundesligaspiel zwischen Hannover 96 und FC Ingolstadt). Die Messung in Abbildung 2c wurde gemeinsam mit VW und IKG durchgeführt, um so zwei Datensätze zu erzeugen (IKG: MMS, VW: Datenfahrrad), die sich räumlich und zeitlich überlagern, so dass Genauigkeiten und Datenfusionsmöglichkeiten untersucht werden konnten.




Abbildung 2.6: Die ausgewählten Pilotgebiete: (links unten) großes Pilotgebiet und Einzugsgebiet Stadion, (rechts unten) kleineres Gebiet für höherfrequente Messungen, (rechts oben) Messung auf dem Gelände der Messe Hannover. © OpenStreetMap contributors

R2.2.1 Erfassung und skalierbare Datenfusion

Um einen optimalen und ununterbrochenen Workflow zu gewährleisten, wurde der Server mit Bedacht konfiguriert und eingerichtet, inklusive Betriebssystem, erforderlicher Software und Zugriffsschnittstellen. Für externe Zugriffsmöglichkeiten und um einen reibungslosen Betrieb sicherzustellen, wurde der Server für ein Server-Housing beim LUIS (Leibniz Universität IT Services) vorbereitet. Nach der Installation innerhalb dieses Services war er vollständig betriebsbereit und dient als robuste Plattform für die Durchführung des Projekts.

Mit einem sorgfältig erstellten Erfassungsplan wurden mehrere Messkampagnen initiiert, um die definierten Pilotgebiete zu erfassen. Diese Kampagnen spielten eine entscheidende Rolle bei der Sammlung von Daten aus unterschiedlichen Szenarien und Ereignissen. Ein spezielles Augenmerk lag auf der Erfassung einer Großveranstaltung – ein Bundesligaspiel zwischen Hannover 96 und dem FC Ingolstadt. Dies diente als primäre Datengrundlage für die Bedarfsermittlung und die Identifikation potenzieller Stellplätze für LIS. Zusätzlich wurden im Rahmen der Hannover Messe Daten von belegten Parkplätzen erfasst.

Die durch unterschiedliche Kampagnen gewonnenen Daten wurden durch ein technisch fortgeschrittenes Optimierungsverfahren fusioniert. Hierbei wurde ein Framework zur Analyse und Interpretation der erhobenen Lidar-Daten entwickelt. Dieses Framework segmentiert die Daten in verschiedenen Verarbeitungsschritten semantisch und stellt Deep Learning-Modelle bereit, die speziell für die analysierten Daten optimiert wurden. Schließlich wurden sämtliche Schritte und Ergebnisse sorgfältig dokumentiert, um Transparenz und Nachvollziehbarkeit zu gewährleisten und eine solide Basis für zukünftige Analysen und Entwicklungen im Rahmen des Projektes zu bieten.

R2.2.2 Analyse der Lidar-Daten

Die erfolgreiche Identifikation von geeigneten und optimalen Stellplätzen für die mobilen Ladesäulen (LIS) ist unmittelbar damit verbunden, räumliche, semantische und temporäre Informationen in den Zielgebieten auszuwerten. Die existierenden Parkmöglichkeiten, dedizierte Parkplätze und Parkmöglichkeiten auf der Straße, stellen die besten Möglichkeiten dar, die LIS so zu platzieren, dass E-Fahrzeug-Nutzende laden können, ohne zusätzliche Wege in Kauf nehmen zu müssen. Dedizierte Parkplätze können mit Hilfe von offenen Datenquellen, z.B. OpenStreetMap, identifiziert werden. Bei Parkmöglichkeiten auf der Straße ist es allerdings so, dass keine Kartierung dazu existiert. Die Parkmöglichkeiten auf der Straße ergeben sich implizit aus der Kombination von Verkehrsregeln, Straßenschildern und Straßenmarkierungen. Im Rahmen des Projekts wurden systematische Aufnahmen in Zielgebiet mit dem Mobile Mapping System (MMS) durchgeführt. Das MMS des IKG erfasst die Umgebung mit Hilfe von zwei Laserscannern (und optional mehreren RGB-Kameras). Hieraus kann eine räumlichen 3D-Punktwolke berechnet werden. Die Aufnahmen wurden mehrfach zu unterschiedlichen Zeitpunkten durchgeführt, was eine temporale Betrachtung erlaubt. In Abbildung 2.7 ist die Analyse-Pipeline zur Verarbeitung der erfassten 3D-Punktwolken schematisch dargestellt. Sie beinhaltet die Schritte „Semantische Segmentierung der Punktwolke“, „Identifikation Fahrzeuginstanzen“ und „Aggregation von geometrischen Informationen der

Fahrzeuginstanzen über die Zeit“. Der letzte Schritt gehört zu der Identifikation möglicher Stellplätze für die LIS und wird in entsprechenden Kontext in Abschnitt zu R3.2.1 beschrieben.




Abbildung 2.7: Daten-Analyse-Pipeline: Daten Erfassung; Semantische Segmentierung; Identifikation der Fahrzeuginstanzen; Akkumulation der räumlichen Daten über die Zeit

Semantische Segmentierung von 3D-Punktwolken: Bei einer 3D-Punktwolke handelt es sich um eine unsortierte Menge von Punkten, die nur durch Ihre räumlichen Koordinaten im dreidimensionalen Raum beschrieben sind. Optional können pro Punkt zusätzliche Informationen wie Farbe und Intensität mitgeführt werden. Isolierte Punkte beinhalten kaum verwertbare Informationen. Wird allerdings eine Gruppe von Punkten in benachbarter Umgebung betrachtet, enthält diese reichhaltige geometrische Informationen. Entscheidend für die erfolgreiche Analyse von Punktwolken ist die Möglichkeit, die Punkte in geeignete Nachbarschaften zu gruppieren. Die räumliche Ausdehnung solcher Nachbarschaften variiert dabei durch Änderungen in der Punktwolkendichte und durch ihren Kontext. Ein Beispiel für eine solche Punktwolke ist in Abbildung 2.8 dargestellt.




Abbildung 2.8: Eine vom MMS erfasste Punktwolke. Die Farben entsprechen semantischen Klassen. Blau: Fahrzeug, grau: Fassade, lila: Fahrbahn, pink: Bürgersteig, gelb: Verkehrsschild, grün: Vegetation.

In Rahmen dieses Projekts wurde das Deep-Learning-Modell KPConv verwendet, das durch die Verwendung von Raster-unabhängigen Faltungen in der Lage ist, mit irregulären Punktwolken effektiv umzugehen. Zudem gehörte es zum State-of-the-art hinsichtlich der semantischen Segmentierung von Punktwolken. Hierbei handelt es sich um eine punktweise semantische Segmentierung, bei der jedem Punkt eine semantische Klasse zugewiesen wird. KPConv wurde

in diesem Fall mit einem intern erstellten Datensatz trainiert, der auf Daten vom MMS basiert. Die Referenz für die semantische Klassifikation der Punkte wurde erstellt, indem korrespondierende RGB-Bilder segmentiert und anschließend auf die Punktwolke übertragen wurden. Schließlich wurden in der Punktwolke Fehler der initialen Segmentierung manuell bereinigt. Das auf diesen Daten trainierte KPConv-Modell ist in der Lage, im Straßenbild typische Klassen zu erkennen. Im Kontext dieses Projekts war besonders die Klasse „Fahrzeug“ interessant. Nach dem Segmentierungsschritt konnten sämtliche Punkte identifiziert werden, die zu einem Fahrzeug gehören. Zur Bereinigung von Fehlklassifikationen konnten bei Bedarf Homogenitätskriterien herangezogen werden, wie z. B. die Regel, dass Punkte einer geschlossenen Fläche zur gleichen semantischen Klasse zugeordnet werden müssen. Da die Klassifikation lediglich punktweise vorlag, war an dieser Stelle noch nicht bekannt, welche Punkte zu bestimmten Fahrzeugen gehörten.

Identifikation von Fahrzeuginstanzen: Hier wurde ein Verarbeitungsschritt umgesetzt, der es erlaubt, innerhalb der Punkte, die der semantischen Klasse „Fahrzeug“ zugeordnet wurden (Abbildung 2.9: Semantische Segmentierung), einzelne Fahrzeuge (Fahrzeuginstanzen) zu identifizieren. Für die Bestimmung der Fahrzeuginstanzen wurde die Nähe der Objekte als Kriterium verwendet. Da die Fahrzeuge (gewöhnlich) so parken, dass kein physischer Kontakt besteht, konnten Verfahren zum Dichte-basierten Gruppieren (Clustern) verwendet werden. Die so identifizierten Gruppen (Cluster) von Punkten bildeten die Fahrzeuginstanzen ab (Abbildung 2.9: Clustering). Abschließend wurden die Cluster regelbasiert gefiltert, um nur die Cluster als Fahrzeuginstanzen zu identifizieren (Abbildung 2.9: Fahrzeuginstanzen), die nicht auf einer Falschsegmentierung entstanden sind. Dazu wurden u. a. Regeln verwendet, die die typischen Dimensionen von Fahrzeugen in Betracht ziehen.




Abbildung 2.9: Die Teilschritte der „Fahrzeuginstanz-Identifikation“: Semantische Segmentierung, Clustering, Fahrzeuginstanzen.

R2.3 Erfassung und Analyse der Fahrzeugsensordaten

Für dieses Ergebnis wurden die notwendigen Schritte implementiert, um Fahrzeugsensordaten DSGVO-konform zu erfassen und zu verarbeiten. Dazu wurde ein eigener Sensoraufbau zur Aufnahme von spezifischen Daten wie Lidar und Kamera, entwickelt. Im Projektverlauf haben wir uns dazu entschlossen, die Aufnahme mittels eines Lastenrads zu realisieren, da dieses flexibel mit verschiedener Sensorik unabhängig von sonst notwendigen Zulassungsverfahren ausgerüstet werden kann.

Im nachfolgenden werden folgende Teilergebnisse beschrieben: *Routenplanung* für die Datenaufnahme, *DSGVO-konforme Datenvorverarbeitung*, *Segmentierung* und *Analyse zur E-Fahrzeugerkennung*.

Routenplanung: Zunächst wurde die Route für die Datenaufnahme festgelegt. Für Testfahrten zur Prüfung der technischen Funktionalität genügen zunächst beliebige Straßenabschnitte im urbanen Kontext. Für die Datenaufnahme der Projektergebnisse sind vor allem die Nähe zu Großveranstaltungen und das Vorhandensein von E-Fahrzeugen maßgeblich. Daher wurde eine Datenaufnahme auf dem Parkplatz der Hannover Messe und eine während eines Ligaspiel des 2. Bundesligavereins Hannover 96 in der Nähe von Stadion und Maschsee festgelegt. Insbesondere die Planung der Datenaufnahme während Großveranstaltungen musste aufgrund der COVID-19-Pandemie mehrfach angepasst werden. Abbildung 2.10 zeigt das Pilotgebiet für die Datenerfassung.




Abbildung 2.10: Pilotgebiet für Datenerfassung. © OpenStreetMap contributors

DSGVO-konforme Datenvorverarbeitung: Um eine DSGVO-konforme Datenaufnahme zu ermöglichen, müssen personenbezogene Elemente aus aufgenommenen Daten durch Anonymisierung entfernt werden. Insbesondere visuelle Komponenten wie Gesichter und Nummernschilder müssen unkenntlich gemacht werden. Dafür wurden geeignete Open-Source Algorithmen ausgewählt, adaptiert und implementiert. Die Verknüpfung aller Sensoren erfolgt im Industriestandard ROS (Robot Operating System⁷), in dem jedes Bild einzeln analysiert wird und Gesichter und Nummernschilder durch Verschwimmen (engl. „blurring“) anonymisiert werden.

Segmentierung: Im Segmentierungsschritt werden Fahrzeugumrisse in RGB-Kameradaten automatisiert erkannt. Hierzu wird der YOLO-v5 Algorithmus zur Objektsegmentierung verwendet. In den segmentierten Bildern können nicht nur Fahrzeuge, sondern auch andere Verkehrsteilnehmer und statische Objekte wie Fahrradfahrer, Hunde oder Bäume segmentiert werden und für weitere Analyseaufgaben genutzt werden.

Analyse zur E-Fahrzeugeterkennung: Die Erkennung von E-Fahrzeugen in den Fahrzeugsensordaten stellt eine beispielhafte Anwendung der erfassten Daten dar, die beispielsweise genutzt werden kann, um den Ladebedarf aus dem Fahrzeugvorkommen abzuleiten. Die Erkennung von E-Fahrzeugen wurde über zwei verschiedene Wege realisiert. Erstens wird über die RGB-Kamera auf eine Kennzeichnung auf dem Nummernschild durch ein abschließendes „E“ geprüft. Zweitens wird die Thermalkamera genutzt, um die Hitzeentwicklung eines Verbrennungsmotors zu erkennen.

Zur Erkennung des abschließenden „E“ auf Nummernschildern wurde der YOLO-v5 Algorithmus eingesetzt, um zunächst das Kennzeichen des Fahrzeugs zu erkennen und dann nach dem „E“ zu suchen.

Zu Erkennung der Hitzeentwicklung wurde die integrierten Thermalkamera genutzt, um die Temperatur am Heck eines vorausfahrenden Fahrzeugs zu erfassen. Da E-Motoren keine Abgase erzeugen und daher keine Auspuffanlage besitzen, kommt es somit auch nicht zur Wärmeentwicklung am Heck des Fahrzeuges. Daher können Verbrenner von E-Fahrzeugen durch die Wärme am Heck mittels eines Temperatur-Schwellwertverfahrens unterschieden werden.

R2.4 Erfassung und Analyse der Web- und Verkehrsdaten

Es wurden verschiedene Web- und Verkehrsdaten extrahiert und analysiert, die für die Schätzung des Ladebedarfs relevant sind.

⁷ <https://www.ros.org/>

Verkehrsdaten

In diesem Abschnitt beschreiben wir zwei verschiedene Arten von Verkehrsdaten: *Floating Car Daten* und *Fahrzeugzulassungsdaten*

Floating-Car-Datensatz: Die Analyse von Verkehrsdaten und des damit verbundenen Ladebedarfs wurde mit Hilfe von Floating Car Data (FCD) durchgeführt. FCD umfasst sequentielle GPS-Koordinaten (Trajektorien), konkret die Standort-, Zeit- und Geschwindigkeitsattribute von Fahrzeugen. Eine Analyse des FCD-Datensatzs bestätigte dessen Qualität und umfassende Verfügbarkeit, die für eine präzise Bedarfsprognose von entscheidender Bedeutung sind.

Die beschafften FCD-Verkehrsdaten enthalten Fahrzeug-Trajektorien aus Niedersachsen und Sachsen von Juli bis Dezember 2019. Unsere Analyse zeigte, dass die Daten von hoher Qualität sind. Insgesamt besteht der Datensatz aus ungefähr 27 Millionen Trajektorien. Zur weiteren Analyse und Aufbereitung der Daten für das Training des Ladebedarfsvorhersagemodells haben wir konkret die Daten für die Stadt Hannover extrahiert. Für dieses Beispiel extrahierten wir alle Trajektorien, die in der Stadt beginnen, enden oder durch sie verlaufen. Insgesamt gibt es ca. 3,5 Millionen Trajektorien (siehe Abbildung 2.11). Davon weisen etwa 35% eine Wegpunkthäufigkeit (Zeitintervall zwischen der Aufzeichnung zweier GPS-Positionen) von weniger als 10 Sekunden auf, und etwa 58% (bzw. 78%) haben eine Häufigkeit von weniger als 20 Sekunden (bzw. einer Minute).




Abbildung 2.11: Endpunkte der Trajektorien im FCD-Daten dazu im Umfeld von Hannover. Karte: © OpenStreetMap contributors

Die Verarbeitung eines Datensatzes dieser Größenordnung bringt rechnerische Herausforderungen mit sich. Um das schiere Datenvolumen zu verwalten, nutzten wir führende Big-Data-Tools und -Frameworks, insbesondere Hadoop und Spark.

Die von GPS-Geräten aufgezeichnete Position weist häufig Fehler auf, so dass die aufgezeichnete Position gegenüber der tatsächlichen Position leicht verschoben ist. Dadurch verschiebt sich bei Trajektorien die erfasste Position geringfügig vom Straßennetz weg. Um solche Fehler zu beheben, wird Map Matching verwendet, das die verschobene Position an das Straßennetz anpasst.

Wir haben zwei Map-Matching-Algorithmen verwendet, um diese Fehler für unsere Daten effektiv zu behandeln. Der Fast-Map-Matching (FMM)-Algorithmus [14], der für Trajektorien mit hoher Frequenz geeignet ist, und STMatch [15], das für niedrigere Frequenzen geeignet ist. Daher haben wir FMM auf diejenigen Trajektorien angewendet, deren Wegpunktfrequenz weniger als eine Minute beträgt, und die anderen Trajektorien mit STMatch.

Außerdem haben wir weitere Unfall- und Verkehrsdaten verwendet und analysiert und neue Algorithmen entwickelt, die auf diesen Daten operieren. Dadwal et al. [16] haben eine neue Methode entwickelt, um Verkehrsdaten gemäß der jeweiligen Problemstellung adaptiv zu clustern. Tempelmeier et al. [17] haben Beziehungen im Straßennetzwerk analysiert, um Stauvorhersagen zu treffen.

Fahrzeugzulassungsdaten: Daten über die Zulassung von Fahrzeugen in den Jahren 2017 bis 2022 wurden vom Kraftfahrtbundesamt eingeholt. Diese Daten geben Aufschluss über die Anzahl der zugelassenen Fahrzeuge in jeder Postleitzahl auf monatlicher Basis. Sie bieten außerdem Einblicke in die Art des verwendeten Kraftstoffs (Benzin, Diesel, Elektro oder Hybrid) und kategorisieren Fahrzeuge in Klassen wie PKW, LKW und Motorrad.

Diese Informationen sind entscheidend für die Prognose des Bedarfs an Ladestationen: Regionen mit einer höheren Zahl an Neuzulassungen von Elektrofahrzeugen werden wahrscheinlich eine größere Anzahl von Ladestationen benötigen, um der wachsenden Nachfrage gerecht zu werden.

Webdaten

Aus dem Web haben wir zwei unterschiedliche Arten von Daten, die für die Ladebedarfsprognose und die Platzierung von Ladestationen von entscheidender Bedeutung sind, extrahiert. Dies sind Daten über Ladestationen und Veranstaltungen sowie Geo-Daten aus Quellen wie OpenStreetMap.

Ladestation-Daten: Relevante Daten über Ladestationen wurden identifiziert und aus Webseiten extrahiert. Dazu gehören unter anderem Informationen über den Standort und die Art der stationären Ladestationen, die Belegung der Ladestationen sowie die Lage von Parkplätzen und Veranstaltungsorten. Insgesamt wurden die folgenden Quellen für Ladestationsdaten ermittelt:

- OpenChargeMap (Web)⁸
- OpenStreetMap (Web)⁹
- OBS|ENERGY (Verkehr)¹⁰

Die umfassende Auswertung ergab, dass die Daten von BS|ENERGY das höchste Niveau haben, auch wenn sie nur 37 Ladestationen in Braunschweig umfassen.

Im Gegensatz dazu enthält OpenStreetMap eine umfangreiche Zusammenstellung von ca. 1.460 Ladestationen in Niedersachsen, für die jedoch zumeist ausschließlich Standortinformationen verfügbar waren. Mittlerweile verfügt OpenChargeMap über die umfangreichste Datenbank mit 2.738 Ladestationen in Niedersachsen – und zwar nicht nur Standortkoordinaten, sondern auch Metadaten wie Adressen, Verwendungsstatistiken und Ladesteckertypen.

Aufgrund dieser Analyse wurde OpenChargeMap als primäre Quelle für Ladeinfrastrukturdaten ausgewählt und bildet den Grundrahmen für die Integration in die d-E-mand-Plattform.

Veranstaltungsdaten: Um den Ladebedarf bei Veranstaltungen zu ermitteln, wurde nach der COVID-Pandemie ein Datensatz von Veranstaltungen erstellt. Der Datensammlungsprozess umfasste unter anderem ein Web-Scraping von Event-Information. Der resultierende Datensatz umfasst geplante Veranstaltungen in der Stadt Hannover für die Jahre 2022 und 2023. In diesem Zeitraum wurden insgesamt 33.206 Veranstaltungen erfasst. Diese Veranstaltungen wurden anschließend in 15 verschiedene Kategorien eingeteilt, darunter Musik (2.205 Veranstaltungen), Theater (1.823 Veranstaltungen) und Sport (206 Veranstaltungen). Der Datensatz umfasst wichtige Veranstaltungsdetails, einschließlich Veranstaltungsnamen, genaue Veranstaltungszeiten und jeweilige Veranstaltungsorte.

Geo-Daten: Der Ladebedarf hängt von den räumlichen Begebenheiten, wie beispielsweise Straßennetzwerken und Points-of-Interests (POI, z. B. Parks und Hotels) ab. Diese Daten können aus OpenStreetMap (OSM) extrahiert und nutzbar gemacht werden. Hierzu wurden im Projekt drei konkrete Lösungen entwickelt, die die Verwendungen von OSM-Daten für Machine Learning verbessern:

- Dsouza et al. [18] haben ein neuronales Netzwerk entwickelt, um Konzepte in OpenStreetMap mit denen in Wissensgraphen wie Wikidata zu verbinden, um so den strukturierten Zugriff auf semantische OSM-Daten zu ermöglichen.
- Tempelmeier et al. [19] haben mit GeoVectors einen Korpus erstellt, der Embeddings, also numerische Repräsentationen, von OSM-Orten bereitstellt, wodurch zum Beispiel Machine-Learning-Prognosen gemäß benachbarter POI ermöglicht werden.

⁸ <https://openchargemap.org>

⁹ <https://www.openstreetmap.org>

¹⁰ <https://www.bs-energy.de>

- Tempelmeier et al. [20] haben eine Methode zur automatischen Erkennung von Vandalismus in OSM-Daten entwickelt, wodurch die Datenqualität von OSM weiter gesteigert werden kann.

R2.5 Methoden der Bürgerbeteiligung

Eine wesentliche Fragestellung im d-E-mand-Projekt war die nach der Bürgerbeteiligung: unter welchen Voraussetzungen können sowohl die Nutzer einer Bürgerbeteiligungsapp als auch der App-Anbieter von einem freiwilligen Datenaustausch profitieren, um den Nutzen der App zu steigern?

Anwendungsfälle

Um relevante Daten für die Ladeinfrastrukturplanung von den vorgesehenen Anwendern, also beteiligten Bürgern, zu sammeln, wurden zunächst Anwendungsfälle für die Integration in die d-E-mand-App entwickelt. Vier Anwendungsfälle wurden definiert, um zum einen die Akzeptanz der d-E-mand-App und die potentiell über Bürgerbeteiligung ermittelten Daten zu bewerten und zum anderen das aktive Feedback der Nutzer zu erfragen:

Anwendungsfall 1	Ladestation finden
Beschreibung	Der Nutzer sucht nach einer Ladestation. Die App zeigt eine Karte mit nahegelegenen Ladestationen. Durch einen Klick auf eine Ladestation können Nutzerbewertungen für eine einzelne Station angezeigt werden. Darüber hinaus werden Daten über die typische Auslastung einer Station angezeigt.
Ziel	Der Nutzer erhält Informationen über nahegelegene Ladestationen.

Anwendungsfall 2	Ladestation bewerten
Beschreibung	Der Nutzer einer Ladestation kann eine Bewertung für eine Ladestation abgeben. Die Bewertung besteht aus einer Anzahl von Sternen (1-5) und einem kurzen Text.
Ziel	Die Bewertung wird in der Bewertungsdatenbank gespeichert.

Anwendungsfall 3	Ladezeitvorschlag erhalten
Beschreibung	Der Nutzer sucht in einem bestimmten Gebiet und in einem bestimmten Zeitraum nach einer Lademöglichkeit und erhält eine Empfehlung, wann voraussichtlich die meisten Ladestationen frei sein werden.
Ziel	Der Nutzer erhält eine Empfehlung für Ladezeit und -ort.

Anwendungsfall 4	Bedarf für Ladestation melden
Beschreibung	Der Nutzer meldet, dass an einem Standort Bedarf für eine weitere Ladestation besteht. Hierzu wird die Position des Nutzers erfasst. Darüber hinaus kann der Benutzer einen kurzen Text hinzufügen, um beispielsweise genau zu beschreiben, wo eine Station platziert werden sollte oder warum die vorhandenen Stationen nicht ausreichen.
Ziel	Die Bedarfsmeldung wird in einer Datenbank gespeichert.

Eine Nutzerstudie wurde durchgeführt, um anhand der Anwendungsfälle eine umfassende Bewertung der Funktionalitäten der Anwendung zu erlangen. Diese Studie war darauf zugeschnitten, wertvolle Erkenntnisse über die vordefinierten Anwendungsfälle, das Potenzial für die Bürgerbeteiligung und die allgemeine Benutzerfreundlichkeit der d-E-mand-Anwendung zu gewinnen. Die Methodik umfasste interaktive Sessions, in denen die Teilnehmer direkt mit der d-E-mand-Anwendung interagierten und wertvolles Feedback zu ihrer Funktionalität und Benutzerfreundlichkeit gaben. Während dieser Sessions wurde zudem ein sorgfältig ausgearbeiteter Fragebogen ausgefüllt, um zusätzliche Erkenntnisse zu gewinnen. Dieser Fragebogen umfasste sowohl Interviews vor als auch nach der Session und enthielt Fragen zu Methoden der Bürgerbeteiligung. In dem Segment vor der Session wurden demografische und nutzungsbezogene Details abgefragt, während das Segment zur Bürgerbeteiligung auf das konzeptionelle Verständnis und die Erfahrungen mit dem Engagement der Nutzer innerhalb der Anwendungen einging. Der Fragebogen endete mit Nachbefragungen, die darauf abzielten, weitere Perspektiven zur Bürgerbeteiligung zu sammeln.

Ergebnisse

Wir beschreiben zunächst unsere Beobachtungen aus den Interviews und leiten anschließend Schlussfolgerungen aus diesen Beobachtungen ab. Zunächst beschreiben wir die allgemeinen Beobachtungen der Teilnehmer zum Thema Bürgerbeteiligung und anschließend die spezifischen Beobachtungen für jeden Anwendungsfall.

Allgemein: Datenweitergabe und Datenschutz

- 2 von 8 Nutzern beteiligen sich aktiv an Online-Bewertungen und waren daher offen für den Datenaustausch.
- Alle Benutzer waren bereit, Daten weiterzugeben, sobald sie den Nutzen verstanden hatten.
- 6 von 8 Nutzern haben Bedenken hinsichtlich des Datenschutzes, etwa hinsichtlich der App-Aufzeichnung ihres Standorts und ihrer Zeit.
- 4 von 8 Nutzern machten sich keine Sorgen um den Datenschutz, sobald sie wussten, dass das Unternehmen oder die App vertrauenswürdig ist.
- Alle Nutzer waren motiviert, Informationen auszutauschen, um die App zu verbessern und der Community zu helfen.

Anwendungsfall 1: Ladestation finden

- Allen Nutzern gefielen die Abschnitte „Nächste Ladestation“, in denen die nächstgelegene Ladestation aufgeführt ist.
- Ein Teilnehmer wollte wissen, ob die Entfernung zur nächsten angezeigten Station zu Fuß oder mit dem Auto sei.
- 4 von 8 Teilnehmern suchten erfolgreich nach einer ihnen bekannten Ladestation.

Anwendungsfall 2: Ladestation bewerten

- 3 von 8 Teilnehmern hätten gerne direkt auf Sterne zur Bewertung geklickt.
- Alle Teilnehmer gaben Feedback zur Einfachheit der Funktion: sie sei intuitiv und ähnlich dem bekannten Google-Bewertungs-Interfaces verständlich.
- Ein Teilnehmer hätte sich mehr Informationen als nur eine Bewertung gewünscht, z. B. die Erwähnung von populären Restaurants in der Nähe o. ä.

Anwendungsfall 3: Ladezeitvorschlag erhalten

- Alle Benutzer äußerten, dass die Funktionalität interessant, einfach und praktisch sei.
- Ein Teilnehmer meinte, es wäre auch interessant, die durchschnittliche Ladezeit und die Anzahl der Autos pro Stunde anzuzeigen.
- Ein Teilnehmer war besorgt über die Genauigkeit der angezeigten Stoßzeit.

Anwendungsfall 4: Bedarf für Ladestation melden

- Alle Teilnehmer fanden die Funktion interessant.
- Alle Teilnehmer äußerten, dass der Funktion leicht zu folgen sei.
- 3 von 8 Teilnehmern schätzen den Kommentarbereich besonders, weil dort der Grund genannt wird, warum in einem bestimmten Gebiet eine Ladestation erforderlich ist.

Zusammenfassung

Die Studienteilnehmer zeigten eine positive Einstellung gegenüber der Bürgerbeteiligung und einem potentiellen Datenaustausch. Sie erkannten die potenziellen Vorteile des

Datenaustauschs im Hinblick auf den persönlichen Nutzen und gesamtgesellschaftliche Verbesserungen. Trotzdem wurden auch Bedenken, insbesondere hinsichtlich der Datensicherheit und Anonymität, geäußert. Die Teilnehmer betonten, wie wichtig es sei, Vertrauen in die hinter der App stehenden Unternehmen aufzubauen.

Die Befragten lobten die benutzerfreundliche Oberfläche und den reibungslosen Navigationsfluss der App. Sie empfanden die vorgestellten Anwendungsfälle als anregend, intuitiv gestaltet und navigierbar. Darüber hinaus machten einige Teilnehmer Vorschläge zur Verfeinerung der Apps bezüglich der Anwendungsfälle in zukünftigen Iterationen.

R2.6 Hardware Sensoraufbau TAAS/MAAS

Teilziel des Projektes war es eine skalierbare, kosteneffiziente Datenerhebung zu ermöglichen. Zumeist ist spezifische Sensorik wie Lidar oder Kamera sehr kostspielig und daher nur für finanziell gut aufgestellte Hersteller, Institute oder Forschungseinrichtungen möglich. Dadurch wird auch die Arbeit an Algorithmen limitiert. Mit dem Sensoraufbau TaaS/MaaS wurde ein Prototyp eines deutlich günstigeren Sensoraufbaus entwickelt. Abbildung 2.12 zeigt den prototypischen Sensoraufbau. Der Aufbau umfasst folgende Sensoren:

2 x Intel Realsense D435i Kameras: D435i-Kameras sind vergleichsweise preisgünstige, aber hochwertige Tiefenkameras von Intel. Jede dieser Kameras besteht aus zwei RGB-Sensoren mit Full-HD-Auflösung, einem Nahinfrarotsensor mit verminderter Auflösung und einer IMU. Ein integrierter Chip erlaubt die sehr einfache Inbetriebnahme der Tiefenkamera, also einem Kamerabild mit Informationen über die Entfernung von Objekten. Allerdings sind diese Kameras durch ihr kompaktes Format nur für eine Entfernung bis etwa 10 Meter ausgelegt, was für Outdoor-Messungen häufig unzureichend ist. Aus diesem Grund haben wir zwei dieser Kameras als Stereo-Setup montiert, was die Bestimmung größerer Abstände auf Kosten der Genauigkeit ermöglicht. Je nach Anwendungsfall kann also entschieden werden, ob Objekte in der Nähe genau bestimmt werden sollen, oder eine große Szene mit verminderter Genauigkeit vermessen werden soll.




Abbildung 2.12: Sensoraufbau für das Datenfahrrad

Zusätzlich kann der dritte Sensor der Kamera bei Bedarf aktiviert werden: der Nahinfrarotsensor. Damit können nicht nur Wärmeinformationen der Umgebung erfasst werden, sondern aufgrund eines „global shutters“ sind Bilder dieses Sensors auch frei von Artefakten aufgrund der Bewegung. Außerdem ist ein Projektor vorhanden, der ein symmetrisches Punktmuster in das Aufnahmefeld projiziert. Die aufgenommene Verzerrung dieses Musters erlaubt eine noch genauere Bestimmung der Entfernung. Da wir die Nahinfrarot-Aufnahmen aber auch für andere Auswertungen nutzen wollen, kann dieser Projektor separat an- und ausgeschaltet werden.

Jede D435i ist außerdem mit einer integrierten IMU ausgestattet, welche bei Bedarf aktiviert werden kann.

Ouster OS0-128 Lidar: Das OS0 Lidar ist ein Sensor zur Erzeugung von Punktwolken aus den Abständen zu Objekten in der Umgebung. Dabei können Objekte in bis zu 100 Metern erkannt und gespeichert werden. Es wird dabei in alle Richtungen nahezu gleichzeitig gescannt, so dass zu jeder Zeit ein umfassender Eindruck über die aktuelle Umgebung vorhanden ist. Auch das OS0 ist mit einer eigenen IMU ausgestattet, die bei Bedarf mit ausgelesen werden kann.

Seek Thermal Kamera: Zur Aufnahme von echten Infrarotbildern wird die Seek Thermal CompactPro genutzt. Im Gegensatz zum Infrarotsensor der D435i wird hier Infrarotstrahlung im mittleren Bereich aufgenommen. Die Handhabung der Daten erfordert allerdings ein deutlich höheres Maß an Nachbearbeitung, da die Aufnahme solcher Strahlung deutlich schwieriger ist.

ZED-F9P GPS Modul: Zur Positionsbestimmung wird ein GPS-Modul von U-Blox genutzt. Neben GPS können damit auch andere Positionierungssysteme wie GLONASS, Beidou oder Galileo genutzt werden. Außerdem unterstützt das Modul die Ausgabe von Rohdaten, mit denen intensive Nachbearbeitung zur zusätzlichen Erhöhung der Positionsgenauigkeit möglich ist.

Alle Sensoren wurden kalibriert, um im ROS in einem gemeinsamen Koordinatensystem räumlich-zeitlich angezeigt zu werden.

R3.1 d-E-mand Datenmodell

Durch die Ausarbeitung eines Datenmodells wurde die effiziente Analyse und Weiterverarbeitung heterogener Daten ermöglicht. Dieses Modell dient als formaler Input für die Extraktion strukturierter Daten und als Grundlage für die Datenintegration im Projekt. Basierend auf den Projektanforderungen und dem entwickelten Datenkatalog wurden relevante Entitäten identifiziert und ein Datenmodell entworfen, das Konzepte aus den Datenquellen repräsentiert.




Abbildung 2.13: Übersicht über das d-E-mand-Datenmodell und das Integrationsframework

Abbildung 2.13 zeigt eine umfassende Darstellung des d-E-mand-Datenmodells und beschreibt verschiedene Datensätze und ihre Beziehungen. Im Mittelpunkt der Abbildung steht OpenStreetMap, das als grundlegende räumliche Referenz dient. In diesem Zusammenhang werden relevante Daten zum Straßennetz, zu Standorten der Ladeinfrastruktur und zu Veranstaltungsorten von OpenStreetMap bezogen. Über ein Map Matching werden darüber hinaus proprietäre Daten, insbesondere Floating-Car-Daten zu Kraftfahrzeugen, mit dem OpenStreetMap-Straßennetz verbunden. Darüber hinaus werden KFZ-Zulassungsdaten auf Basis von Postleitzahlen mit räumlichen Informationen angereichert.

Die Prognosemodelle erfordern Informationen über die möglichen LIS-Standorte in einer generalisierten Form (Geo-Punkte/Polygone). Diese Anforderung wurde unter Verwendung von offenen Datenquellen wie OpenStreetMap und ATKIS/ALKIS erfüllt. Für die Analysedaten aus den MMS-Messkampagnen wurde eine Pipeline implementiert, um Informationen entsprechend zu generalisieren und anschließend in einem Application Programming Interface (API) bereitzustellen.

R3.2 Prognosemodelle für mobile und stationäre LIS

Wir haben verschiedene Prognosemodelle entwickelt, die im Folgenden beschrieben werden.

Modell zur Vorhersage der Ladeauslastung

Für die Vorhersage der Auslastung von Ladestationen für Elektrofahrzeuge wurde mit DFDS (Deep Fusion of Dynamic and Static Information) ein neuronales Netzwerk entwickelt [21]. Die Architektur des Netzwerks ist in Abbildung 2.14 dargestellt.




Abbildung 2.14: Encoder-Decoder Architektur zur Prognose von Ladestationsauslastungen

Das neuronale Netz nutzt hierfür Gated Recurrent Units (GRUs), die sich besonders für das Lernen aus Zeitreihen eignen. Die GRUs werden in einer Encoder-Decoder-Architektur verwendet, in der die neuesten historischen Beobachtungen kodiert und in eine Vorhersage dekodiert werden. Darüber hinaus nutzen wir statistische Merkmale, insbesondere 75%-Quantile aus den Nutzungsstatistiken. In unseren Experimenten zeigt sich, dass DFDS im Durchschnitt 3,45% Prozentpunkte besser als die Baselines ist (gemäß F1-Score).

Modell zum Wissenstransfer aus verschiedenen Städten

Um mit Deep-Learning-Modellen genaue, raum-zeitliche Vorhersagen zu erzielen, sind erhebliche Datenmengen erforderlich, die nicht immer verfügbar sind, beispielsweise nicht in ausgewählten Städten. Um dieses Problem anzugehen, haben wir ein in Abbildung 2.15 zu sehendes, auf Meta Learning basiertes Modell – MetaCitta [22] – entwickelt, das das Training in solchen Fällen zu erleichtern.

MetaCitta nutzt das Wissen aus Städten mit umfangreichen Daten und wendet es effektiv auf eine Zielstadt an, in der es an verfügbaren Daten mangelt. In diesem Szenario ermöglicht MetaCitta bessere Prognosen als aktuelle Baselines und ist zudem wesentlich effizienter.




Abbildung 2.15: Meta-Learning-basierter Ansatz zum Wissenstransfer von datenreichen Städten in eine datenarme Stadt

Modell zur Platzierung von Ladestationen

Hier diskutieren wir zwei Ansätze, die für die Ermittlung optimaler Platzierungen fehlender Ladestation entwickelt wurden.

Reinforcement-Learning-Ansatz: Die Bestimmung des optimalen Standorts für eine Ladestation ist ein komplexes Unterfangen, das von Faktoren wie Wartezeiten, Reisedauer und Infrastrukturkosten beeinflusst wird. Mit unserem auf Reinforcement Learning basierenden Ansatz [23] wird die Bereitstellung der Ladeinfrastruktur im gesamten betrachteten Gebiet optimiert. Gleichzeitig werden Wartezeiten, Fahrten und Ladezeiten innerhalb vordefinierter Budgetgrenzen minimiert. Die Ergebnisse dieses Ansatzes für eine ausgewählte Region in Hannover sind in Abbildung 2.16 visualisiert.

Mit dieser Methodik zur Platzierung von Ladestationen kann die Wartezeit, verglichen mit existierenden Methoden, um bis zu 97% verringert werden.




Abbildung 2.16: Die Platzierung der Ladestation auf einem Gebiet von Hannover nach Anwendung des Ansatzes

Ansatz zur Ladestation-Platzierung auf Basis von MMS-Messkampagnen: Prognosemodelle erfordern Informationen über die möglichen Ladestation-Standorte in einer generalisierten Form (Geo-Punkte/Polygone). Diese Anforderung wird bei Verwendung von offenen Datenquellen wie OpenStreetMap und ATKIS/ALKIS-Daten direkt erfüllt. Für die Analysedaten aus den MMS-Messkampagnen wurde eine Pipeline implementiert, um Informationen entsprechend zu verallgemeinern und anschließend in einem Application Programming Interface (API) bereitzustellen [24].

Die Pipeline konvertiert im ersten Schritt die Fahrzeuginstanzdaten in Footprints der Fahrzeuge. Im Kontext unserer Aufgabenstellung sind wir an der 2D-Belegung in der lateralen Ebene interessiert. In einem folgenden Schritt werden die 2D-Belegungsinformationen in ein Raster diskretisiert, das eine Kumulation der Informationen über die Zeit erlaubt. Wir erhalten somit Informationen über die Anzahl der Fahrzeuge, die im Beobachtungszeitraum eine bestimmte Zelle belegt haben, und wann die Belegung stattgefunden hat. Die kumulierten Belegungsinformationen lassen eine Reihe von Analysen zu, wie z. B. über den Zeitpunkt des höchsten Parkdrucks in einer Straße oder Aussagen über die Ausprägung des Parkverhaltens auf implizit definierten Parkplätzen.

In folgenden Schritten wird angenommen, dass, wenn bei einer Anzahl der beobachteten Belegungen einen bestimmten Schwellenwert übersteigt, es sich dabei um einen möglichen Parkplatz und somit um einen möglichen Stellplatz für eine LIS handelt. Da isolierte einzelne Parkplätze suboptimal bei der Platzierung neuer Ladesäulen sind, werden dabei zusammenhängende Gruppen von Parkplätzen präferiert.

Im finalen Schritt werden die Daten vektorisiert und in Form von Geo-Punkten und Polygonen durch eine RESTful API für die weitere Verarbeitung bereitgestellt.

Web-Tool

In d-E-mand-Projekt wurde ein Web-tool entwickelt, das Daten und Prognosemodelle visualisiert. Im Zentrum des Tools befindet sich eine Karte, auf der Daten räumlich visualisiert werden. Wie in Abbildung 2.17 zu sehen, befindet sich auf der linken Seite ein Bedienfeld, um zwischen verschiedenen Modi zu wechseln.




Abbildung 2.17: Visualisierung der Neuzulassungen von elektrischen Fahrzeugen pro Postleitzahl in Hannover

Modus 1: Neuzulassungen von Elektrofahrzeugen pro Postleitzahl

Abbildung 2.17 zeigt die Webansicht der KFZ-Neuzulassungen für Elektrofahrzeuge. In dieser Ansicht werden die Zulassungszahlen von Elektrofahrzeugen im Zeitraum 2017 bis heute pro Postleitzahl in Hannover visualisiert. Jeder Postleitzahlenbereich ist in einem Blauton gefärbt. Je dunkler der Blauton, desto höher ist die Zahl der bisher zugelassenen Elektrofahrzeuge. Das Diagramm rechts oben zeigt den Verlauf der Zulassungen in einem ausgewählten Postleitzahlgebiet pro Monat.

Modus 2: Schätzung des Ladebedarfs

Abbildung 2.18 zeigt die Visualisierung der Ladebedarfsprognose in Hannover. Die Schätzung basiert auf einem Raster, das die Fläche in gleiche Rasterzellen unterteilt. Die Rasterzellen sind blau eingefärbt. Je dunkler der Blauton, desto höher ist der geschätzte Ladebedarf. Zur Abschätzung des Ladebedarfs werden verschiedene Faktoren berücksichtigt, die im linken Bedienfeld individuell aktiviert oder deaktiviert werden können. Derzeit können folgende Faktoren für die Prognose berücksichtigt werden:

- **Vorhandene Ladestationen:** Vorhandene Ladestationen werden auf der Karte als rote Punkte angezeigt. Je mehr Ladestationen in einer Rasterzelle vorhanden sind, desto geringer ist der Ladebedarf in dieser Rasterzelle.

- FCD-Reisedaten: Berücksichtigt proprietäre Floating-Car-Daten (FCD). Je mehr GPS-Spuren in einer Rasterzelle enden, desto höher ist der geschätzte Ladebedarf.
- Fahrzeugzulassungen: Unter der Annahme, dass in Gebieten mit einer hohen Anzahl zugelassener Elektrofahrzeuge auch ein erhöhter Bedarf an Ladesäuleninfrastruktur besteht, nutzen wir die Zulassungszahlen zur Prognose des Bedarfs.




Abbildung 2.18: Ansicht zur Visualisierung der Ladebedarfsprognose (statisch)

Modus 3: Dynamischer Ladebedarf

Im Modus 2 basiert die Bedarfsschätzung auf statistischen Faktoren wie der Fahrzeuganzahl und der vorhandenen Ladeinfrastruktur. Im Gegensatz dazu verwendet Modus 3 (Abbildung 2.19) einen dynamischen Ansatz. Hier wird der Bedarf mithilfe eines Deep-Learning-basierten Modells prognostiziert, das anhand der in AP 2 gesammelten Daten trainiert wurde. Im linken Bereich der Nutzeroberfläche befindet sich ein Schieberegler, so dass die Prognosen für jede auf der Karte visualisierte Rasterzelle im Verlaufe der Zeit angezeigt werden können. Das Modell ist darauf ausgelegt, in 30-Minuten-Intervallen Prognosen für jede Gitterzelle zu erstellen.




Abbildung 2.19: Ansicht zur Visualisierung der Ladebedarfsprognose (dynamisch)

R3.3 Reichweitenschätzung

Es wurde ein Prototyp für einen RangeEstimation-Service, also die Reichweitenschätzung durch kontextuelle Bedingungen, entwickelt. Das zu Grunde liegende RangeEstimation ist eine Methode zur Berechnung der Restreichweite eines Elektrofahrzeugs. Der Ablauf umfasst die Vorbereitung der Eingabedaten, die Berechnung von Energie- und Leistungswerten sowie die Merkmalsberechnung sowohl für die bereits gefahrene als auch die noch zu fahrende Route. Die Grundidee besteht darin, die Fahrt in verschiedene Abschnitte zu unterteilen, diese zu clustern und die Restreichweite auf Basis von gewichteten Clusterwerten zu bestimmen [25]. Abbildung 2.20 zeigt schematisch das Vorgehen zur RangeEstimation.




Abbildung 2.20: Schema RangeEstimation

Die zeitliche und geometrische Länge der einzelnen Abschnitte werden als Eingabevariable aus dem Trip Monitoring übergeben. Für die historische, bereits gefahrene Strecke werden weitere Eingabegrößen wie SOC, GPS, Geschwindigkeit, zurückgelegte Distanz, Stromstärke und Spannung als Zeitreihen über den Logger der Fahrzeugbatterie bezogen. Energie und Leistung werden aus den Stromstärke- und Spannungsdaten ebenfalls als Zeitreihen ermittelt.

Für jeden Abschnitt werden die Merkmale Durchschnittsgeschwindigkeit und -leistung sowie durchschnittliche spezifische Energie berechnet. Dabei kommen verschiedene statistische

Verfahren zum Einsatz, die gewährleisten, dass möglichst das typische Fahrverhalten erfasst wird, z. B. werden die stärksten Ausreißer entfernt, aber charakteristische behalten.

Abhängig von Durchschnittsgeschwindigkeit und -leistung werden die Abschnitte in eines der folgenden fünf Cluster eingeteilt, von denen jedes ein bestimmtes Fahrprofil definiert:

Clustertyp	Beschreibung
Parken	Leistung und Geschwindigkeit gleich 0
Stadtverkehr	langsames Fahren mit wenig Leistungsbedarf
Überlandfahrt	schnelles Fahren mit wenig Leistungsbedarf
Bergauf	langsames Fahren mit hohem Leistungsbedarf
Autobahn	schnelles Fahren mit hohem Leistungsbedarf

Analog wird für die Vorhersage der noch zu fahrenden Strecke vorgegangen, wobei dafür auf die Werte und Erkenntnisse aus den historischen Werten zurückgegriffen wird. Hintergrund ist, dass der Algorithmus mit der Zeit lernt und die Restreichweite mit zunehmender Genauigkeit bestimmt.

Schließlich wird der durchschnittliche Energieverbrauch für jedes Cluster berechnet und entsprechend der Abschnittsanzahl in den Clustertypen gewichtet. Die Restreichweite wird dann als Quotient aus aktuell verfügbarer Ladekapazität – d. h. dem aktuellen SOC und der maximalen Batteriekapazität – und durchschnittlichem Energieverbrauch ermittelt.

Der RangeEstimation-Service wird von dem Trip Monitoring-Service verwendet.

R3.4 Trip Monitoring

Über den Trip Monitoring Service können von einer LIS-Navigation geplante Fahrten hinterlegt werden. Diese hinterlegten Fahrten werden überwacht bezüglich aktueller Verkehrslage (Graphmaster), Restreichweite (RangeEstimation-Service aus R3.3) sowie Verzögerungen hinsichtlich der geplanten Ankunftszeit. Der Service ist im Grunde ein Complex Event Processing (CEP) System und wurde mit der CEP-API *Siddhi* realisiert. Die Kommunikation mit der LIS-Navigation sowie mit dem RangeEstimation-Service erfolgt über einen RabbitMQ Message Broker. Das Complex Event Processing System verarbeitet die Informationen der verschiedenen Quellen und löst Hinweismeldungen aus, wenn die aktuelle Route eingeschränkt ist, sich die Fahrt deutlich verlängert oder wenn das Ziel durch eine sinkende Restreichweite nicht mehr erreicht werden kann. Die LIS-Navigation wird dann per Hinweismeldungen über notwendige Nachladungen an (mobilen) Ladesäulen entlang der Strecke informiert. Auch bei potenziellen Verzögerungen auf Grund der Verkehrslage werden Hinweismeldungen gesendet.




Abbildung 2.21: Gesamtarchitektur LIS-Navigation, Tripmonitoring und RangeEstimation

Die Gesamtarchitektur zum Zusammenspiel von LIS-Navigation, Message Broker, Trip Monitoring und RangeEstimation ist in Abbildung 2.21 zu sehen. Sowohl für den Trip Monitoring-Service als auch für das Range-Estimation-Service wurden Continuous Integration Pipelines sowie Deployment-Pipelines eingerichtet, mit denen die Services leicht weiterentwickelt und aufgesetzt werden können.

R4.1 Plattformkonzept

Die d-E-mand-Plattform hat folgende Anforderungen zu erfüllen:

- **B2C-App:**
 - Frontend-Applikationen für Elektrofahrzeug-Nutzer:innen
 - Ladestationen anzeigen
 - Routenfindung für Nutzer:innen mit Elektrofahrzeugen
 - Bürgerbeteiligung (Ladebedarf melden, Ladesäulen bewerten, Konfiguration des eigenen Fahrzeugs, Hinterlegen von Orten, bspw. Heimadresse oder Arbeitsplatz)
- **B2B-App:**
 - Frontend-Applikationen für LIS-Betreiber:innen und Veranstalter:innen
 - Integration der APIs der Konsortialpartner:innen:
 - **L3S** (Events/Veranstaltungen an einem gegebenen Tag, sowie Bedarf an zusätzlichen mobilen Ladestationen an einem bestimmten Ort)
 - **IKG** (Kandidatenstellplätze mit ihren Koordinaten sowie Kapazität)
 - **VW** (Empfehlung, wie viele mobile Ladeplätze auf welchen Stellplätzen bereitgestellt werden sollen)

Folgende Systemkomponenten sind dabei entstanden:

- **Frontend:**
 - B2C-Frontend als native App für Android und iOS (mit Möglichkeit einer mobilen Web-Version)
 - B2B-Frontend als Web-Desktop Applikation
- **Backend:**
 - Gemeinsame Middleware für B2C und B2B, welche alle nötigen Schnittstellen und Services für die Frontend-Applikationen orchestriert
 - Integration von dritten APIs und Verarbeitung der Daten aus diesen APIs
 - Datenbank zum Speichern der Daten aus der Bürgerbeteiligung

Verwendete Technologien

Das Frontend wurde dabei mit folgendem Technologie-Stack umgesetzt: **Capacitor**, **Angular** mit **Typescript** und **RxJS**:

Capacitor ist ein nativer Container, mit dem webbasierte Apps auf Android, iOS, Desktop und im Browser ausgeführt werden können.

Angular ist ein Typescript-basiertes Web-Framework. Es zielt auf die Entwicklung von Web-Anwendungen und legt großen Wert auf Struktur und Qualität.

TypeScript ist eine Programmiersprache, die auf den Vorschlägen zum ECMAScript-6-Standard basiert und Sprachkonstrukte wie Klassen, Vererbung, Module und anonyme Funktionen unterstützt.

RxJS ist eine Programmbibliothek für reaktive Programmierung. Dabei wird asynchron und event-basiert mittels Observable Sequences und LINQ-artigen Abfrage-Operatoren programmiert. Dieses Tech-Stack wurde gewählt, da wir firmenintern schon lange damit arbeiten und eine gewisse Expertise und auch Boilerplate Code besitzen, was eine sehr effiziente Umsetzung der Software ermöglicht hat.

Für die Entwicklung des Backends wurden **Node.js/Apollo Server**, **GraphQL** und **MySQL** genutzt.

Node.js ist eine plattformübergreifende Open-Source-JavaScript-Laufzeitumgebung, die JavaScript-Code außerhalb eines Webbrowsers und somit **Apollo-Server** als Serveranwendung ausführen kann. Somit stellt dieser Verbund eine Basis-Anwendung dar, welche hauptsächlich Typescript als Programmiersprache nutzt und die verschiedenen

Als Kommunikationsprotokoll zwischen Frontend und Middleware wurde sich für **GraphQL** entschieden, welches auf einem REST-Service aufbaut. Die Anwendung von GraphQL begründet sich darin, dass nur für das User-Interface notwendige Daten von der Backend-Anwendung geliefert werden können. Die Modelle der Datenbank für die Umsetzung der Use-Cases zur Bürgerbeteiligung im Backend wurden mit MySQL erstellt und mit AWS Relational Database Services umgesetzt. Zugriff erhält die Backend-Applikation via AWS SDK

Zusätzlich zu den genannten Bibliotheken und Sprachen kamen noch folgende weitere externe Anwendungen zum Einsatz: **Redux** und **MapBox**. **Redux** wird im Frontend als eine quelloffene JavaScript-Bibliothek zur Verwaltung von Zustandsinformationen in einer Webanwendung genutzt. Mapbox ist ein amerikanischer Anbieter von benutzerdefinierten Online-Karten für Websites und Anwendungen und dient in den Frontend-Applikationen als Träger aller Darstellungen und Interaktionen mit Karten. Hierfür wurde auch in vorherigen Projekten ein Wrapper entwickelt, welcher die Benutzung und Erweiterung der Mapbox Karte sehr effizient gestaltet und gut an die Voraussetzungen des d-E-mand Projektes angepasst werden konnte.

Die Implementierung der Benutzeroberfläche der B2C-Applikation wurde mit Hilfe des Frameworks Angular realisiert und setzt somit das Model-View-Controller Pattern um. Dabei wurden die reinen Frontend-Komponenten, welche keine Datenhaltung besitzen und nur für die Kommunikation mit dem Nutzer zuständig sind (Dateneingabe und Datenausgabe), mittels der Programmierbibliothek Storybook implementiert. Weiterhin setzt die durch die Verwendung von Angular gegebene Software-Architektur diejenigen Komponenten um, welche die Kommunikation zwischen den o.g. reinen Frontend-Komponenten und den Serviceklassen bis hin zur Middleware übernehmen. Für das globale State-Handling der Frontend-Anwendungen fungiert ein Redux-Store, welcher auch über asynchrone Anfragen aus den Zugriffen auf die Middleware gespeist wird.

Da die B2B-App mit demselben Architekturansatz umgesetzt wurde (Ausnahme ist der Zugriff über das Information Interface auf die Middleware, dies wurde hier übersprungen und die APIs direkt über die API-Services angesprochen), konnten viele Frontend-Komponenten wiederverwendet werden. Deshalb wurden für die Applikation auch nicht in zwei Repositories

angelegt, wie es normalerweise der Fall ist. Wurden in der B2C-Applikation Designs und Komponenten angepasst, so musste dies nicht an ein zweites Repository übertragen werden. Zudem konnte über das Lazy Loading der Angular Router Struktur verhindert werden, dass alle Komponenten geladen werden, wenn man den jeweilig respektiven Teil der Applikation aufruft, wodurch die Applikation performant geblieben ist. Beim Lazy Loading werden nur die Module geladen, welche auch gerade gebraucht werden.

Abbildung 2.22 stellt die Software-Architektur der Frontend-Komponenten der B2C-App sowie der B2B-Plattform dar:




Abbildung 2.22: Software-Architektur der Frontend-Komponenten B2C und B2B

Zusammensetzung der Tech-Stacks

Während der Konzeption der B2B-App wurde schnell klar, dass durch die zeitliche Restriktion eine Einbindung aller benötigten APIs für die B2B-App in den bestehenden B2C-Middleware/Backend Tech-Stack nicht möglich war, weswegen sich dafür entschieden wurde, die Kommunikation mit den APIs über Service-Klassen direkt aus der Frontend-Applikation zu realisieren, wie in Abbildung 2.23 dargestellt.




Abbildung 2.23: Kommunikation mit den APIs in der B2B Applikation

R4.2 Plattform Release

Die Plattform-Releases teilen sich in verschiedene Versionen auf. Die erste Version beinhaltet die Deployment-Mechanismen und die Umsetzung der grundlegenden Kommunikations-Architektur der einzelnen Software-Komponenten mithilfe von Amazon Web Services (AWS).

Die zweite Version behandelt die Weiterentwicklung der B2C-Anwendung mit Navigation (optimiertes Matching), intermodales Routing, Fahrzeugkonfiguration, Bürgerbeteiligung (Ladestation bewerten, Bedarf für Ladestation melden, Ladestation suchen, Ladezeitpunkt empfehlen) und Trip-Monitoring. Die dritte Version behandelt die B2B-Anwendung und einen Überblick über die genutzten APIs.

Das Deployment und die Verwaltung der d-E-mand Plattform wurde in AWS verwirklicht. Abbildung 2.24 zeigt dazu die Systemarchitektur des AWS Umfeldes.




Abbildung 2.24: Systemarchitektur des AWS Umfeldes

Sowohl das Frontend als auch das Backend werden über AWS Elastic Container Service gehostet. Sowie das Frontend der B2B-App, als auch das gemeinsame Backend werden in ihren respektiven Clustern gehostet und über Tasks gestartet. Dafür werden beide Applikationen lokal in ihrer respektiven Umgebung gebaut und zu einem Docker Container gebündelt. Diese werden dann mithilfe der AWS CLI und Docker Push in die Elastic Container Registry geladen und mit dem Task verknüpft. Damit die Nutzeranfragen an den Server unter jeder Last verarbeitet werden können, wurde ein Application Load Balancer eingesetzt, durch die Verteilung der Anfragen auf unterschiedliche aktive Serverinstanzen.

Überwacht werden die beiden Cluster über Cloudwatch. In diese werden alle Logs der Cluster geleitet und können überprüft werden.

Das Frontend des Minimum Viable Products für die B2C-App beinhaltet in dem Stand der App zum Ende des Projektes Navigation, speziell für Elektrofahrzeuge, intermodales Routing, Fahrzeugkonfiguration, Bürgerbeteiligung und dem TripMonitoring des Fraunhofer IVI. Die Navigation umfasst dabei auch einen optimierten Matching Algorithmus für Ladestationen. Technisch wurden die oben genannten Softwarekomponenten komplett in der Architektur wie beschrieben umgesetzt.

Nachfolgend werden die einzelnen Komponenten aufgeführt und kurz erläutert.

Navigation

Die Navigation in der B2C-App wurde mithilfe einer intern verwendeten TripRequest API umgesetzt. Dabei sind zwei Wege zur Routenabfrage möglich: Zum einen ist eine Navigationsanfrage ohne Daten eines Elektrofahrzeugs möglich.

Zum anderen ist eine Anfrage möglich, wenn es Informationen zu einem Elektrofahrzeug gibt: Namentlich die Restreichweite, die Gesamtreichweite, den Verbrauch und die kompatiblen Steckertypen, wird ein eigener entwickelter optimierter Matching Algorithmus angesprochen.

Dieser berechnet mit den oben genannten Variablen eine Route, in der die Reichweiten des Fahrzeugs berücksichtigt werden.

Optimierter Matching Algorithmus

Grundlage der Routenfindung für Elektrofahrzeuge stellt der sogenannte optimierte poi_matching_algorithmus dar. Ein Schema dazu ist in folgender Abbildung zu sehen. Der Algorithmus befindet sich in einem abgekapselten Paket und wird von der d-E-mand Middleware angesprochen, wenn Daten eines Elektrofahrzeuges mit in die Routenfindung gegeben werden. Mithilfe der Restreichweite, den benutzbaren Steckertypen, der Gesamtreichweite und der Art der Optimierung wird die bestmögliche Route gefunden. Dies beinhaltet bei der bestmöglichen Optimierung die theoretisch schnellste Route bezogen auf Fahrt- und Ladedauer. Abbildung 2.25 zeigt das Schema des Matching Algorithmus.




Abbildung 2.25: Schema des Matching Algorithmus

Intermodales Routing

Eine weitere Möglichkeit, wie ein:e Nutzer:in die Navigation verwenden könnte, ist das intermodale Routing.

Dieses beschreibt im Groben die Möglichkeit, verschiedene Method of Transportation's für dieselbe Strecke zu verwenden. Dabei gibt es zwei Wege, wovon jedoch nur eine im Rahmen des optimierten Matching Algorithmuses getestet wurde. Die erste Möglichkeit beschränkt sich darauf, dass der oder die Nutzer:in bestimmt, welche Teilstrecke er oder sie mit den öffentlichen Verkehrsmitteln und welche er/sie mit dem eigenen Elektroauto zurücklegen möchte.

Dabei kann aufgrund von technischen und zeitlichen Restriktionen nur ein Wechsel der Transportmethode stattfinden. Abbildung 2.26 zeigt Ansichten aus der App zum intermodalen Routing.




Abbildung 2.26: Ansicht intermodales Routing

Bürgerbeteiligung

Unter diesem Stichwort sind in der App vier Features entwickelt und implementiert worden (siehe auch R2.5).

- Ladestation bewerten
- Bedarf für Ladestation melden
- Ladestation finden
- Ladezeitpunkt empfehlen

1. Ladestation bewerten

Der/die Nutzer:in kann eine Bewertung für eine Ladestation abgeben. Die Bewertung besteht aus einer Sternenzahl (1-5). Abbildung 2.27 zeigt die relevanten Ansichten in der App.




Abbildung 2.27: App Screens zu "Ladestation bewerten"

2. Bedarf für Ladestation melden

Der/die Nutzer:in meldet, dass an einem Ort Bedarf für eine weitere Ladestation besteht. Dazu wird die Position des Nutzers erfasst. Außerdem kann der/die Nutzer:in einen kurzen Text beifügen, etwa um genau zu beschreiben, wo eine Station platziert werden könnte oder warum die existierenden Stationen nicht ausreichen. Abbildung 2.28 zeigt die relevanten Ansichten in der App.




Abbildung 2.28: App Screens zu “Ladebedarf melden”

3. Ladestation suchen

Eine Hauptfunktion der B2C-App ist die Möglichkeit, dass Nutzer:innen Ladestationen suchen und weitere Informationen zu diesen erhalten können. Dies geschieht im Navigationsbereich “Suche”. Standardmäßig werden den Nutzer:innen Ladestationen in einem Umkreis von einem Kilometer Umkreis vom eigenen Standort angezeigt. Sie können aber auch eine Adresse in das Suchfeld eingeben, von der aus sie Ladestationen angezeigt bekommen wollen. Die Ladestationen werden auf einer Karte und einer Liste angezeigt. Außerdem können bestimmte Filter eingesetzt werden (Steckertyp, Leistung, Betriebsbereitschaft). Abbildung 2.29 zeigt die relevanten Ansichten in der App.




Abbildung 2.29: App Screens zu “Ladestation suchen”

4. Ladezeitpunkt empfehlen (Stoßzeiten)

Der/die Nutzer:in sucht eine Lademöglichkeit in einem bestimmten Gebiet und während eines Zeitrahmens. Er/sie erhält eine Empfehlung, zu welchem Zeitpunkt die meisten Ladestationen voraussichtlich frei sind. Der/die Nutzer:in erhält eine Empfehlung zum Ladezeitpunkt (und Ort). Abbildung 2.30 zeigt die relevanten Ansichten in der App.




Abbildung 2.30: App Screens zu „Stoßzeiten“

Fahrzeug konfigurieren

Nutzer:innen können über das Steckersymbol oder über die Einstellungen in das Fahrzeugsconfigurationsmenü gelangen. Dort kann er:sie entweder die Marke und den Typ seines Elektroautos auswählen oder die Werte manuell eingeben. Zu den manuellen Werten gehören die Gesamtreichweite, der Verbrauch auf 100km, und die nutzbaren Steckertypen. Wählt der:die Nutzer:in sein Fahrzeug aus der vorgegebenen Liste, so sind die Daten für die gängigsten Marken und Modelle fest hinterlegt. Die Daten stammen von Charge Trip und können in einer Weiterentwicklung auch als API an die App angeschlossen werden, sodass es immer eine aktuelle Liste aller gängigen Elektrofahrzeuge gibt.

Trip Monitoring

Als erste dynamische Erweiterung und Ausbau der Navigation wurde das Trip Monitoring des Fraunhofer IVI implementiert. Idee ist es mithilfe von Echtzeitdaten die Restreichweite während der Fahrt zu updaten, sodass Alternativrouten und auch neue Ladestationen auf der Strecke gesucht werden könnten. Das Trip Monitoring befindet sich in der d-E-mand App in einem Testzustand. Es ist zur Zeit nur möglich, jeweils ein Gerät gleichzeitig an die API anzubinden. Genauso kommen in unserer Version auch keine in Echtzeit gespeisten Daten, sondern nur Testnachrichten zurück. Die Einbindung in der d-E-mand App dient als reines Proof of Concept, das eine Anbindung an eine Subscription überhaupt funktioniert und bei Eingang einer Nachricht darauf reagiert werden kann. Abbildung 2.31 zeigt die relevanten Ansichten in der App.



Abbildung 2.31: Ansicht Trip Monitoring

App-Development und Frontend Deployment

Wie zuvor erwähnt, wurde die Angular Struktur verwendet. Um das Frontend zu veröffentlichen, wurde ein Capacitor Wrapper für die App genutzt. Mit diesem Wrapper ist es möglich, Angular Code zu schreiben, der in der Entwicklung einer normalen Website gleicht. Anschließend werden die nativen App, Wrapper für Android und Apple hinzugefügt und die lokale Angular Web App kann als native Android App in Android Studio oder wahlweise auch auf einem Gerät sowie in XCode betrachtet werden. Mithilfe von Fastlane ist es dann auch möglich, die Testversionen in die jeweiligen App Stores zu veröffentlichen.

Als zweite Frontend-Entwicklung wurde die B2B-App veröffentlicht. Die finale Umsetzung beinhaltet eine minimierte Version des Designs. Abbildung 2.32 zeigt die Detailansicht der B2B-App für eine einzelne Veranstaltung.

Es wurden alle Funktionen entfernt, die nicht zum Proof of Concept der APIs eigetragen hätten.

Aufgeteilt ist die B2B-App in drei Teile: Die Seitenleiste, welche für zukünftige Unterseiten gedacht ist, die Veranstaltungsliste und die Übersichtskarte.




Abbildung 2.32: Detailansicht einer Veranstaltung mit geöffnetem Filtermenü

R4.3 API und Microservices

Grundsätzlich wurde mit der ersten Version der d-E-mand-Plattform-API die Kommunikationsarchitektur zwischen Frontend- und Backend-Anwendungen, wie in Abschnitt „Verwendete Technologien“ beschrieben, realisiert. Dabei orchestriert das d-E-mand-Backend verschiedene APIs, welche die für die Nutzenden relevanten Informationen bereitstellen. Außerdem wurden erste Routen z.B. für die Abfrage von Geolocations, Ladeinfrastruktur oder die Abfrage einer einfach Graphmasters-Navigationsroute implementiert, um das Konzept der Serveranwendung auf seine Belastbarkeit zu prüfen.

Die Version 2 des d-E-mand-Backends erweitert die API um umfangreiche Funktionen, wie die Informationsabfrage für die UseCases zur Bürgerbeteiligung, die Routenabfrage für die Ladeinfrastruktur-Navigation, sowie die Anmeldung für das TripMonitoring-Backend des Konsortialpartners Fraunhofer IVI.

Folgende APIs der Konsortialpartner wurden integriert:

- L3S: Eventabfrage und Berechnung der Vorhersage des Ladebedarfs für ein Event
- IKG: Berechnung der Kandidatenstellplätze für die zusätzlich benötigte Ladeinfrastruktur für ein Event
- VWN: Abfrage der Standorte für die tatsächliche Platzierung der mobilen Ladeinfrastruktur

R5.1 Dashboard und Planung der E-Mobilitätsservices

Zielgruppen B2B allgemein

Für eine Anwendung im B2B Bereich kommen viele sehr unterschiedliche Zielgruppen in Frage. Jede dieser Zielgruppen hat andere Bedürfnisse an eine B2B-Anwendung, daher sollte jede Gruppe eine andere Ansicht mit anderen Möglichkeiten haben.

Folgende Zielgruppen könnten durch eine B2B-Anwendung angesprochen werden:

- Verkehrsplaner:in
- Anbieter:in mobiler Ladestationen
- Anbieter:in stationärer Ladestationen
- Veranstalter:in
- Elektrofahrzeuge-Flottenbetreiber:in
- Stromanbieter:in
- Autohersteller:in
- Betreiber:innen mobiler Ladestationen

Wir haben uns im Folgenden auf die Veranstalter:innen und Betreiber:innen mobiler Ladestationen fokussiert.

Wireframes und Screendesigns

Anhand von zuvor priorisierten User Stories konnten wir beginnen, Wireframes für die Anforderungen zu skizzieren und diese groben Skizzen dann anschließend in detaillierte Screendesigns übertragen. Es folgen, zum besseren Verständnis, einige Beispiele aus den Screendesigns. Diese bilden nicht die ganze Anwendung ab und sollen lediglich einen groben Eindruck vermitteln.

Startseite (aus Sicht Veranstalter:innen)

Beim Öffnen der Anwendung landen die Nutzer:innen zuerst auf einer Startseite (Abbildung 2.33). Dort kann er oder sie sehen, welche Veranstaltungen wann und wo stattfinden und welchen Ladebedarf sie haben (Wie viele Ladestationen sie benötigen). Außerdem können die oder die Nutzer:innen sehen, ob er oder sie neue Nachrichten erhalten hat, z. B. von Ladestations-Betreiber:innen, die er oder sie angefragt hat. Des Weiteren finden die Nutzer:innen hier einen Absprung in den Prozess "Planen Sie eine neue Veranstaltung".

Veranstaltung planen (aus Sicht Veranstalter:innen)

Klickt der oder die Nutzer:in auf den Button „Neue Veranstaltung planen“ öffnet sich ein Prozess, in dem der oder die Veranstalter:in die eigene Veranstaltung, mit Daten wie Datum, Ort, Besucherzahl, angeben kann. Abbildung 2.33 zeigt die Ansicht zum Planen von Veranstaltungen.

Abbildung 2.33: d-E-mand B2B, Veranstalter: Veranstaltung planen

Empfehlung (aus Sicht Veranstalter:innen)

Auf der Grundlage der eingetragenen Daten bekommt der oder die Veranstalter:in eine Empfehlung ausgespielt. Dort erhält der oder die Nutzer:in u. A. Informationen darüber, wie viele Ladestationen zusätzlich benötigt werden, wie viele Elektrofahrzeuge in etwa zu erwarten sind. Abbildung 2.34 zeigt die Ansicht mit Empfehlungen.




Abbildung 2.34: d-E-mand B2B, Veranstalter: Empfehlung für die Veranstaltung

Ladestationen anfragen (aus Sicht Veranstalter:innen)

Wir gehen davon aus, dass der oder die Nutzer:in nach der Empfehlung mit großer Wahrscheinlichkeit Ladestationen anfragen bzw. für die eigene Veranstaltung dazu buchen möchte. Deswegen kann er oder sie „Ladestationen anfragen“ klicken und landet in einer Liste. Hier werden Ladestations-Betreiber:innen angezeigt und deren Angebote, aus denen Veranstalter:innen auswählen und Anfragen schicken können.

Startseite (aus Sicht Ladestation-Betreiber:innen)

Wir gehen davon aus, dass Ladestation-Betreiber:innen vor allem daran interessiert sind zu sehen, an welchen Orten wie viel Bedarf an Ladestationen besteht, um die eigenen Ladestationen möglichst gewinnbringend platzieren zu können. Deswegen kann der oder die Nutzer:in hier die Bedarfe an Ladestationen von Veranstaltungen, Elektro-autofahrer:innen und der Öffentlichkeit in Form einer Liste und auf einer Karte ansehen (siehe Abbildung 2.35).




Abbildung 2.35: d-E-mand B2B, Zielgruppe LIS Betreibende: Startseite

Kartenansicht (aus Sicht Ladestation-Betreiber:innen)

Der oder die Nutzer:in gelangt auf eine Kartenansicht, sieht den Bedarf (in diesem Fall die Veranstaltung) im Fokus und kann auf der linken Seite unterschiedliche Filter einstellen. Mögliche Filter wie z. B. Parkplätze, öffentliche Ladestationen und andere Veranstaltungen können eingeblendet werden. Außerdem bekommt der oder die Nutzer:in eine Empfehlung angezeigt, an welchen Orten die Ladestationen am besten platziert werden sollten.

R5.2 Apps für E-Verkehrsteilnehmer mit LIS-Informationen, sowie Bürgerbeteiligung

Screendesigns

Abbildung 2.36 zeigt Eindrücke der Screendesigns der App.




Abbildung 2.36: Von links nach rechts: Erfolgsmodal, Ladestation bewerten, Detailinformationen zu einer Ladestation

Umfragen und Interviews

Zu unserer B2C-Zielgruppe gehören alle Personen, die regelmäßig ein Elektroauto fahren, die sogenannten E-Mobilisten.

Um diese Menschen und deren Verhalten besser kennenzulernen, haben wir eine Umfrage mit dem Online Tool "Tally" erstellt und diese an möglichst viele Menschen ausgespielt. 67 Personen haben an der Umfrage teilgenommen. Mit sieben Personen, die gut in unsere Zielgruppe passen, haben wir zusätzlich Tiefeninterviews geführt.

Usertesting B2C

Allgemeines

Das Usertesting wurde mit 5 männlichen Testpersonen durchgeführt, die regelmäßig Elektroauto fahren. Das Testen wurde 2021 mit einem Clickdummy remote durchgeführt. Es wurden verschiedene Szenarien durchgespielt. Beim Testing wurde die Think aloud Methode verwendet, bei der die Testpersonen ihre Gedanken laut äußern. Bei jeder Sitzung hat eine Moderator:in, eine Protokollant:in und eine Proband:in teilgenommen.

Hintergrund und Ziel des Usability-Tests

Ziel des Tests

Ziel war es, die d-E-mand App auf Usability testen, da das Konzept und das Design bisher nur auf Annahmen basierte. Wir wollten durch den Test herausfinden, ob die Benutzer:innen die App verstehen und die Aufgaben lösen können. Aus diesem Grund wählten wir drei Aufgaben, aus verschiedenen Bereichen aus, um ein möglichst breites Spektrum abzudecken.

Research Ziel

Durch den Test sollte die Nutzbarkeit der App getestet und bewertet werden. Unter anderem sollte geklärt werden, wie die Proband:innen das Produkt verstehen, was ihr mentales Modell ist und ob wir ihre Erwartungen erfüllen konnten.

In dem Test wurden drei kurze Aufgaben gestellt, die einen Großteil des Entwicklungsstands der App repräsentieren. Die Proband:innen sollen mittels Think-Aloud Methode ihre Eindrücke, Erfahrungen und Gedanken mitteilen. Anhand ihrer Aussagen wurden Insights und daraus Handlungsempfehlungen generiert.

Testaufgaben und Erkenntnisse

Aufgabe 1: Fahrzeug konfigurieren

Aufgabenstellung:

„Du hast über das Internet von der d-E-mand App gehört. Dir gefällt es besonders, dass die App die verbleibenden Reichweite deines Autos kalkulieren kann.“

Nachdem du dir die d-E-mand App auf dein Smartphone geladen hast, öffnest du diese zum ersten Mal. Bevor du weitere Funktionen nutzen kannst, musst du dein Auto, einen Audi E-Tron S, in der App konfigurieren.“

Erkenntnisse

- Nutzer:innen, die versuchen das Fahrzeug zu konfigurieren, gehen ausschließlich über das Menü und nicht über das Shortcut Icon, weil das verwendete Symbol auf den ersten Blick nicht mit dieser Funktion in Verbindung gebracht wird.
- Nutzer:innen, die versuchen, ihr Fahrzeug zu konfigurieren, verstehen den Button „Manuell konfigurieren“ nicht, weil keine genauere Beschreibung vorhanden ist.
- Nutzer:innen, die versuchen, ihr Fahrzeug zu konfigurieren, suchen nach einer Möglichkeit ihre favorisierten Ladesäulen-Anbieter zu hinterlegen, diese ist aber nicht vorhanden.

Aufgabe 2: Plane deine Route

Aufgabenstellung:

„Da du nun dein Auto konfiguriert hast, möchtest du vor Antritt der Fahrt deine Route eingeben, um an dein Ziel zu navigieren.“

Du möchtest Freunde in Hamburg besuchen. Suche eine Route von deinem aktuellen Standort zur Adresse „Hikeberg 2, 22043 Hamburg“ und navigiere dort hin.“

Erkenntnisse:

- Nutzer:innen, die versuchen eine Route zu planen, erwarten, dass der Reichweiten Slider in Prozent angezeigt wird, da dies bei den Fahrzeugherstellern ebenfalls der Fall ist.
- Nutzer:innen, die versuchen eine Route zu planen, wählen in allen getesteten Fällen den Weg über das Widget im "Homescreen", da dies für sie als erstes sichtbar ist.
- Nutzer:innen, die versuchen eine Route zu planen, möchten sich bei der Detailansicht der Route genauer über die Ladestops erkundigen, um sich für eine Route entscheiden zu können.
- Nutzer:innen, die mehr Informationen zu einer Ladestation suchen, versuchen Details in der Routenplanung abzurufen, weil diese Informationen zur Entscheidungsfindung beitragen.
- Nutzer:innen möchten wissen, worin sich Route A, B, C unterscheiden. Sie würden klassifizieren nach: Am schnellsten, Beste Lademöglichkeiten ("Lade-Versprechen"), keine Autobahn, um eine passende Entscheidung zu treffen.
- Nutzer:innen, die versuchen, in der Suche der Routenplanung die Hausnummer des Ziels einzugeben, verstehen das Vorgehen nicht, weil das Interaktionsmuster für sie ungewohnt ist.
- Nutzer:innen, die versuchen eine Routenplanung über den Homescreen zu starten, wählen als erste Stelle das Ziel aus, da sie davon ausgehen, dass der App ihren Standort bekannt ist und sie den Start ggfs. später anpassen möchten.

Aufgabe 3: Bewerte deine nächste Ladestation

Aufgabenstellung

„Seit deinem Besuch bei deinen Freunden in Hamburg sind ein paar Tage vergangen und du bist zurück in Hannover. Du nutzt dein E-Auto und lädst deinen Wagen regelmäßig an der Ladestation in der Nähe. Weil sie dir besonders gut gefällt, willst du die Ladestation Shell Jädekamp Hannover bewerten.“

Erkenntnisse

- 3 Tester wünschen sich, dass sie das Bewerten Layer oben bei den Sternen öffnen können
- Grundsätzlich kommen alle Nutzer mit der Bewertung zurecht. Ein Tester empfindet die Bewertung als „simpel und üblich wie bei Google Bewertungen“
- Ableitungen / Verbesserungsmöglichkeiten
- Sterne auch oben anklickbar machen: Die Anzeige der Sterne in der Übersicht oben sollte auch tapbar sein und das Bewerten Modal öffnen
- Rezension schreiben ermöglichen: Ein Tester würde sich weitere Informationen zu der Ladestation wünschen, eine Idee könnte sein, dass User zusätzlich zur Bewertung auch in einem Freitextfeld ihre Erfahrung mit anderen Elektroauto-Fahrern teilen können.
- Nutzer:innen sollten Feedback bekommen, wenn sie bewertet haben, z. B. „Vielen Dank, dein Feedback hilft, die App zu verbessern.“
- Nutzer:innen sollten sehen können, ob sie eine Ladestation bereits bewertet haben und wie.
- Nutzer:innen sollte sehen können, wieviele E-mobilisten eine Ladestation bewertet haben

Allgemeine Erkenntnisse

Aus unseren Studien haben wir folgende wesentliche Erkenntnisse gesammelt:

- App wird als zeitgemäß wahrgenommen
- Nutzer:innen kommen mit der Bedienung der App größtenteils zurecht
- Die App wird als wenig innovativ wahrgenommen
- Viele würden die App nicht nutzen, da sie nicht direkt mit dem eigenen Fahrzeug kommuniziert

R4.4 IDS-Connectoren

Für dieses Ergebnis wurde an einer IDS-kompatiblen Connector-Implementierung mitgearbeitet. Das IVI hat sich in die Konzeption, Entwicklung und dem Testen einer Data Space-Connector ¹¹ Implementierung mit den Anforderungen der Use Cases des Projekts eingebracht. Dieser Connector steht nun als Open Source zur Verfügung und kann in weiteren Projekten eingesetzt werden.

R4.5 Verknüpfung mit weiteren Datenplattformen

In AP 4.5 wurde die Connector-Implementierung aus AP 4.4 genutzt, um Anbindungen an die MDM-Plattform¹² zu erproben und dort Straßenverkehrsdaten abzurufen sowie sich mit Teilnehmern des Mobility Data Spaces¹³ zu verbinden.

Das Connector-Konzept ist in der Abbildung 2.37 dargestellt.




Abbildung 2.37: Abbildung 6 IDS Connector Konzept

¹¹ <https://github.com/International-Data-Spaces-Association/DataspaceConnector>

¹² <https://www.mdm-portal.de/>

¹³ <https://mobility-dataspace.eu/>

R6.1.1 Trainingsmaterial für die Pilotierung in Hannover

Zu Erstellung des Trainingsmaterials für die Pilotierung wurden im ersten Schritt geeignete Use-Cases für die Pilotierung ausgewählt. Dann wurden Clickdummies für die Pilotierung und erstellt und schließlich die geplante Pilotierung dokumentiert.

Bewertung der Use Cases: Die Use-Cases aus der Anforderungsanalyse wurden mit Hilfe einer Bewertungsmatrix systematisch bewertet. Folgende Use-Cases wurden bewertet:

- Use-Case 1: Bedarfsermittlung/Kapazitätsplanung für Veranstalter,
- Use-Case 2: Optimale Standort- und Kapazitätsplanung im öffentlichen Straßenraum, Use-Case 4: Informieren über Verkehrslage und Restreichweite,
- Use-Case 5: Informieren über (mobile) LIS-Verfügbarkeiten.

Die Bewertungsmatrix enthält mögliche Umsetzungen der Pilotierung, die Testgruppe, Dauer der Pilotierung, notwendige Zuarbeit von Projektpartnern, in welchem Quartal die Pilotierung angestrebt wird, wie realitätsnah die Ergebnisse der Pilotierungsidee sein werden, inwiefern sie die implementierten Funktionen abbildet, ob sie organisatorisch umsetzbar ist und was die Bewertungskriterien in der Pilotierungsidee sein werden.

Aufgrund der Bewertungsmatrix wurde die B2B- und die B2C-Anwendung zur Pilotierung ausgewählt, da diese auf den restlichen technischen Arbeitspaketen basieren und somit große Teile der technischen Arbeiten des Gesamtprojekts umfassen. Konkret wurden für die Pilotierung der Anwendungen in Hannover Use-Case 1 und 2 ausgewählt, während UseCase4 und 5 für die Pilotierung in Dresden und den überregionalen Szenarien bestimmt wurden.

Erstellung des Trainingsmaterials: Für die Pilotierung wurde ein Clickdummy für Use Case 1 und 2 durch die Projektionisten bereitgestellt. Dazu wurde aus dem Konzept der B2B-Anwendung navigierbare Screens erstellt. Diese Screens ähnelten einer fertigen Desktop-Anwendung und enthielten alle zentralen Funktionalitäten des Konzepts. Aus den Screens wurde eine Klickstrecke gebaut, die an einigen Stellen Abzweigungen enthielt. Dadurch konnte der Nutzer auf verschiedene Symbole auf dem Screen klicken und dadurch sofort an den nächsten Screen geleitet werden. Dies erzeugte beim Tester das Gefühl, eine tatsächliche Anwendung zu benutzen. Die entstandene Klickstrecke wird im nachstehenden Text als Clickdummy bezeichnet. Abbildung 2.38 und Abbildung 2.39 zeigen beispielhafte Ansichten aus dem Clickdummy.

Ziel der Pilotierung war es, die Anwendungen einzeln Domänenexperten vorzustellen, um relevantes Feedback zu erfassen. Dazu wurden geeignete Aufgaben für die Experten erarbeitet. Die Aufgaben wurden so gestellt, dass der Experten sich durch den Clickdummy klicken und viele verschiedene Funktionen nutzen musste, um ans Ziel zu gelangen.

Des Weiteren wurde ein Interview zur Erfassung der jeweils relevanten Expertise vorbereitet: Das Interview wurde mit einem einleitenden Frageblock begonnen, in dem die Tester zu ihrer

Arbeit, ihrer Motivation und ihrer Erfahrung mit Elektromobilität befragt wurden. Danach kam der Aufgabenblock, in welchem die Tester den ClickDummy benutzten. Im Aufgabenblock gab es neben den Aufgabenanweisungen offene Fragen, die die Tester dazu bringen sollten, uns ihre Gedanken, die sie zu den Screens und Funktionen hatten, mitzuteilen. Zuletzt wurde allgemeines Feedback zum ClickDummy und eine Prognose zur Zukunft der Elektromobilität eingeholt.

Für die Pilotierung wurden fünf Expert:innen aus den Bereich Veranstaltungsplanung Elektromobilität ausgewählt. Dabei wurde Wert darauf gelegt, dass die Tester sich hinsichtlich Arbeitserfahrung, Arbeitsbereich, Geschlecht, Alter und regionaler Zugehörigkeit unterschieden, sodass trotz der geringen Anzahl von Testern verschiedene Perspektiven gehört werden würden.




Abbildung 2.38: Clickdummy für Pilotierung aus Sicht eines LIS-Anbieters




Abbildung 2.39 Clickdummy für Pilotierung aus Sicht eines Veranstaltungsplaners

R6.1.2 Ergebnisse der Pilotierung in Hannover

Mit den fünf Experten wurden jeweils ein- bis anderthalbstündige Interviews per Videokonferenztools durchgeführt. Dies hatte den Vorteil, dass die Tester bei ihrer Arbeit mit dem ClickDummy am Desktop optimal beobachtet werden konnten.

Zur Evaluation der Ergebnisse der Pilotierung in Hannover wurde die Methode der qualitativen Inhaltsanalyse genutzt. Als Kategorien wurden dazu „positiv“, „negativ“, „Handlungsanweisung“ und „Sonstiges“ gewählt. Die Aussagen wurden zusätzlich nach Funktionalitätsblöcken geordnet.

Im Folgenden werden die wichtigsten Erkenntnisse der Pilotierung zusammengefasst:

1.) Veranstaltungsplaner bevorzugen es, immer mit demselben Ladesäulenbetreiber zu arbeiten. Eine andauernde Geschäftsbeziehung ist ihnen wichtiger, als jedes Mal den günstigsten Preis zu bekommen. Beim Erstkontakt steht für sie vor allem der Preis oder aber die Qualität des Anbieters im Vordergrund. Das der d-E-mand B2B-Anwendung zugrundeliegende Konzept sieht aber vor, dass für jedes Event eine neue Geschäftsbeziehung angeknüpft wird. Daraus folgt, dass das Konzept dergestalt umgearbeitet werden muss, dass die B2B-Anwendung nicht primär als Kontaktplattform fungiert, sondern als Planungstool für Ladesäulen bei Veranstaltungen.

2.) Die Veranstaltungsplaner wünschen sich ein Rundum-Sorglos-Paket, die näheren Details der Ladesäulenplanung sind für sie nur von untergeordneter Bedeutung. Wichtig ist, dass alle Logistik vom Ladesäulenbetreiber übernommen wird, d.h. Aufbau, Abbau, Inbetriebnahme, Hin- und Rücktransport. Vor allem ist essentiell, dass ein 24-Stunden lang erreichbarer Ansprechpartner zur Verfügung gestellt wird. Das bisherige d-E-mand Konzept sah jedoch vor, dass die Veranstaltungsplaner einige der Planungsaufgaben mithilfe der Anwendung erledigen. Hierzu zählt vor allem, dass der Veranstalter den Ladebedarf in Ladesäulen mithilfe der Anwendung abschätzt und diese an den Ladesäulenbetreiber schickt. Hier zeigte sich, dass die Veranstalter sich sehr schwer damit tun, den Bedarf abzuschätzen und die Ladesäulenbetreiber wiederum die Rahmendaten über die Veranstaltung wissen wollen, um die Angaben zu überprüfen. Daher wäre eine Verbesserungsmöglichkeit, diese Aufgaben dem Ladesäulenbetreiber zu überantworten. In diesem Fall würde die wesentliche d-E-mand Funktionalität des Veranstalters an den LIS-Betreiber übertragen werden. Die Plattform würde also zum Planungstool für Ladesäulenbetreiber.

3.) Die Ladesäulenbetreiber vertrauen nicht blind auf einen Algorithmus, der ihnen die optimalen Standorte für mobile Ladesäulen vorschlägt. Sie verfügen über sehr viel Domänenwissen und Erfahrung, sodass es für sie wichtig ist zu verstehen, warum und auf Basis welcher Datengrundlage der Algorithmus seine Entscheidung fällt. Außerdem haben sie uns viele Daten und Informationen genannt, die wir zusätzlich in unseren Algorithmus einbeziehen sollten, z. B. die Dichte an Mehrfamilienhäusern und Bevölkerungsdichte. Es zeigt sich, dass der Algorithmus sehr gute Platzierungsvorschläge liefern muss, da er sonst keinen

Mehrwert für die Ladesäulenbetreiber bietet. Um den hohen Ansprüchen der Ladesäulenbetreiber zu genügen, müssen wir umfassende und hochwertige Echtweltdaten nutzen, um die Platzierungsvorhersagen zu treffen.

4.) Der Planungsprozess dauert länger als angenommen, nämlich mehrere Wochen bis zu einem Monat. Während die Kontaktaufnahme mit der Stadt wegen öffentlich geführten Parkplätzen zügig abläuft, ist es schwierig, E-Mail-Adresse und Telefonnummer von Betreibern privater Parkplätze zu ermitteln. Hier könnte die Anwendung einen echten Mehrwert schaffen, indem sie die notwendigen Kontaktinformationen bereitstellt. Zusätzlich wäre es für die Ladesäulenbetreiber spannend, wenn zu jedem privaten Parkplatzbetreiber eine Bewertung oder Text mit Vorerfahrungen hinterlegt ist. Der Text könnte zum Beispiel beinhalten, ob der Parkplatzbetreiber gerne mobile Ladesäulen auf seinem Parkplatz stehen hat, ob er schnell reagiert etc.

5.) Die B2B-Anwendung arbeitet mit mobilen Ladesäulen. Tatsächlich hängt die Zukunft mobiler Ladesäulen stark von der Entwicklung stationärer Ladesäulen ab, da mit fortschreitendem Ausbau des stationären Netzes immer weniger mobile Ladesäulen gebraucht werden. Andererseits wird es für Veranstaltungen auf dem Land und bei temporärem starkem Mehrbedarf immer Bedarf an mobiler Ladesäuleninfrastruktur geben. Dieser Punkt stellt also ein Risiko für den wirtschaftlichen Erfolg der Anwendung dar, kann aber bei sorgfältiger Ausrichtung gemildert werden.

Insgesamt waren alle Tester positiv überrascht davon, wie weit das Konzept bereits ausgestaltet waren und empfanden die Idee als sehr spannend. Sie attestierten dem Tool, dass es profitabel sein könnte, wenn es als echte Anwendung auf den Markt käme.

R6.2 Trainingsmaterial für die Pilotierung in Dresden

Es wurden zunächst Daten von 25 Testfahrten erhoben. Diese erhaltenen Daten umfassen die Trajektorien der gefahrenen Routen, die Anfangs- und Endzeiten, die Ladestände (Anfang/Ende, selbst berechnet/laut Fahrzeug), Fahrzeiten- und -längen sowie die Logs aus den Trip Monitoring und RangeEstimation Services mit potenziellen und tatsächlich ausgegebenen Benachrichtigungen. Über eine Datenbank können jeder Fahrt weitere Fahrzeug- und Streckendaten zugeordnet werden. Siehe Abbildung 2.40.

Die Testfahrten in Dresden und überregionaler Umgebung dienten dem Test der Datenanbindung sowie der Services Trip Monitoring und RangeEstimation.

Der Test der Datenanbindung umfasste zum einen die Übertragung der Fahrzeugdaten an die Datenbank per Mobilfunk, die Übertragung der Subscriptions und Notifications von der B2C-App der LIS-Navigation zum Trip Monitoring und zurück per Mobilfunk. Zum anderen wurde die Ankopplung der Dienste RangeEstimation, Graphmasters API, OpenTopoData API sowie des Message Brokers RabbitMQ an das Tripmonitoring im praktischen Einsatz getestet.




Abbildung 2.40: Datenbank mit weiteren Strecken- und Fahrzeugdaten

Der Test des Trip Monitoring Services umfasste eine Plausibilitätsprüfung bezüglich der Berechnung von Verspätungen und Restreichweiten, die Synchronisation der zu überwachenden Trips mit der aktuellen Verkehrslage, die Korrektur der aktuellen Position aus den Fahrzeugdaten über den RangeEstimation Service, die Korrektur der aktuellen Position alternativ über das Positionsupdate, die Notifications bei Fahrtbeginn mit initialer Reichweite, die Notifications wenn keine Reichweiteninformationen vorliegen, die Notifications bei signifikanten Verspätungen, die Notifications über einen kritischen Zustand bei zu geringer Restreichweite sowie die korrekte Einhaltung der Kriterien für die Ausgabe der Notifications.

Der Test des RangeEstimation Services umfasst eine Evaluierung des Modells für die Reichweitenprognose, der Evaluierung des Lernens der Modellparameter auf Grund des aktuellen Kontextes (bisheriger Fahrtabschnitt unter gegebener Temperatur, Heizung/Klima-Zustand und Fahrstil), die Evaluierung des Modells für die Reichweitenprognose für die weitere Fahrt auf Grund der gelernten Modellparameter sowie des Wissens über den weiteren Fahrtverlauf (Verkehrslage, Geschwindigkeiten, Höhenprofile). Weiter war das Lernen und die Prognose der Klassenzugehörigkeit der Fahrtabschnitt (Klassen: Parken, Stadtverkehr, Überland, Bergauffahrt, Autobahn) sowie der Berücksichtigung dieser Klassen Gegenstand der Untersuchungen. Das Verhalten beim Ausliefern der aktuellen Positionen des Fahrzeuges an das Trip Monitoring wurde auch beobachtet.

R6.2 Ergebnisse der Pilotierung in Dresden

Für die Auswertung der während der Tests erhobenen Daten und Logs wurden die einzelnen Fahrten in Graphiken transformiert. Beispielhaft werden 4 Fahrten in Abbildung 2.41, und Abbildung 2.42 gezeigt. Die Bilder zeigen die Trajektorie der Fahrt in Punkten. Das heller werdende Grün symbolisiert eine abnehmende Restreichweite und der Radius der Kreise symbolisiert die Verzögerung der aktuellen Fahrt im Vergleich zur geplanten Fahrt. Die erste Fahrt zeigt ein Szenario, bei dem der Status zu Beginn der Fahrt „ok“ war (initiale Notifikation nach Subskription), sich aber wegen der später ergebenden kontextuellen Bedingungen (eingeschaltete Klimaanlage, Fahrt auf Waldweg) auf „critical“ geändert hat und vom Trip

Monitoring eine Notifikation nachgereicht wurde. Später wurde noch wegen einer beginnenden Verzögerung eine Notifikation gesendet. Die Fahrt auf dem zweiten Bild auf Abbildung 2.41 ist durch eine verkehrsbedingte Verzögerung gekennzeichnet. Am Start wird nach der Subskription direkt die erste obligatorische Notifikation gesendet, nach dem ersten Anzeichen einer Verzögerung die zweite Notifikation. Bei starker Vergrößerung der Verzögerung um 10 min erfolgt eine weitere dritte Notifikation und die vierte Notifikation erinnert nach einer halben Stunde an die noch vorhandene Verzögerung. Auf dem nächsten Bild (Abbildung 2.42/1) wird direkt nach der Subskription die obligatorische Notifikation mit der initialen Reichweite gesendet, worauf eine unterbrechungsfreie Fahrt folgt. Bei Einfahrt in urbanes Gebiet wird die anfängliche Verzögerung gemeldet, danach entsteht durch Stau eine größere Verzögerung, über welche bei einer Erhöhung der Zeitdauer der Verzögerung um 10 min erneut eine Notifikation gesendet wird. Bei der vierten Fahrt (Abbildung 2.42/2) wird die initiale Notifikation mit Status „ok“ gesendet. Die Reichweite ist zwar knapp bemessen, aber ein sicheres Erreichen des Ziels ist gewährleistet. Durch die Veränderung der Verkehrssituation im bald zu befahrenden urbanen Raum muss die Reichweitenschätzung wegen der Aussicht auf „Stopp and Go“ korrigiert werden und die Fahrt verfällt in den Status „critical“. Tatsächlich kommt es später beim Befahren des urbanen Raumes zu starken Beeinträchtigungen des Verkehrsflusses und zu einem sehr langem „Stopp and Go“. Durch die resultierende Verzögerung und eben durch die kritische Reichweite werden viele Notifications gesendet.

Tatsächlich können für alle 25 Fahrten die Notifications gut auf Grund der vorgegebenen Kriterien nachvollzogen und als richtig ausgegeben erkannt werden. In Situationen wie im letzten Beispiel werden eventuell zu viele Notifications ausgegeben. Das ist jedoch nachvollziehbar, wenn man sich die Definitionen der auszugebenden Events im Complex Event Processing (CEP) ansieht. Es werden sowohl Events auf Grund von Kriterien bezüglich der Verzögerungen und auch Events auf Grund der Kriterien bezüglich der Restreichweite weitergereicht. Hier könnte Nachbesserung bei den Definitionen der Events gewünscht werden. Ansonsten funktioniert der Trip Monitoring Service wie gewünscht.

Im Folgenden soll ein Blick auf den RangeEstimation-Service gelegt werden. Hierfür wurden die vom RangeEstimation geschätzten Restreichweiten mit den Reichweiten verglichen, die vom Fahrzeug selbst berechnet wurde. Es wurden die Reichweiten am Anfang und am Ende jeder Testfahrt genutzt. Die resultierenden 50 Datenpunkte sind in Abbildung 2.43 zu sehen. Jeder Datenpunkt zeigt auf der x-Achse die vom Fahrzeug selbst berechnete Restreichweite und auf der y-Achse die vom RangeEstimation berechnete Reichweite. Die diagonale Gerade stellt die Orte im Diagramm dar an denen die vom Fahrzeug angezeigte Reichweite, mit der vom RangeEstimation prognostizierten Reichweite übereinstimmen. Es ist zu sehen, dass die Datenpunkte um diese Diagonale streuen. Die geschätzten Restreichweiten stimmen also im Mittel mit den vom Fahrzeug angezeigten Reichweiten überein. Die Abweichungen entstehen natürlich, weil sich beim RangeEstimation die berücksichtigten kontextuellen Bedingungen besser oder schlechter auf den Energieverbrauch auswirkten.

Abschließend soll noch auf die Verkehrsinformationen aus der Graphmasters API geschaut werden. Für die Überwachung der Fahrten im Tripmonitoring werden Informationen über die einzelnen Streckenabschnitte wie Streckenlänge, Geschwindigkeit und Zeitverbrauch verwendet. Diese werden von der Graphmasters API geliefert. Zusätzlich werden Höhendaten von einer OpenTopoData API verwendet. In Abbildung 2.44 werden die geplanten Dauern der Fahrten mit den tatsächlichen Dauern der Fahrten verglichen. Jede Fahrt wird in der Abbildung

als Datenpunkt dargestellt. Die geplante Dauer der Fahrt wird auf der x-Achse des Diagramms abgetragen. Die tatsächliche Dauer der Fahrt wird auf der y-Achse abgetragen. Die diagonale Gerade zeigt die Orte im Diagramm an denen die geplanten Dauern mit den tatsächlichen Dauern übereinstimmen. Im Diagramm ist zu erkennen, dass die benötigten Dauern stets größer waren als die geplanten Dauern. Die geplanten Routen sind also sehr sportlich und nicht von jedem Fahrer zu schaffen. In Nachfolgeprojekten sollte man somit auch bei der Schätzung der Verkehrslage mehr Kontext (Fahrstil, Wetter, Straßenverhältnisse) verwenden.

Die „Lessons Learned“ stellen wichtige Projektergebnisse dar und sollen hier festgehalten werden:

Das Trip Monitoring überwacht derzeit eine einzelne geplante Fahrt und setzt Zeit und Ort des Endes dieser Fahrt als Ziel. Muss die Fahrt von der LIS-Navigation geändert werden, würde eine neue Fahrt mit neuem Ziel vom Trip Monitoring überwacht werden. Beispielsweise ist beim Anfahren einer Ladestation die Ladestation das örtliche Ziel, das zeitliche Ziel ist die Ankunftszeit dort. Tatsächlich ist es aber doch so, dass ein Nutzer ein ganz konkretes örtliches und zeitliches Ziel hat. Beispielsweise um 15:00 Uhr in Berlin am Hauptbahnhof zu sein. Deshalb sollte in Nachfolgeprojekten das Trip Monitoring auf das Erreichen eines übergeordneten konkreten Ziels ausgelegt sein. Einzelne Fahrten, zum Beispiel zu einer Ladestation, sollten nur als eine notwendige Teiletappe zum Erreichen des Gesamtziels gesehen werden.

Die RangeEstimation führt derzeit Berechnungen aus, die zu lange dauern, um für viele Fahrzeuge und für lange Fahrten zur Verfügung stehen zu können. Diese Berechnungen sind im Grunde das Lernen der Parameter des Prognosemodells für den bereits abgeschlossenen Fahrtabschnitt und das Prognostizieren der Restreichweite auf Grund der Verkehrslage des noch zu fahrenden Fahrtabschnittes. Da der RangeEstimation-Service ein zustandsloser Dienst ist, werden bei jeder *Anfrage* die Berechnungen immer wieder ausgeführt. In Nachfolgeprojekten könnte man die Berechnungen beschleunigen in dem man einen zustandsbehafteten Dienst verwendet, bei dem die Fahrten dem Dienst bekannt sind und somit bei jeder Anfrage auf bereits berechnete Ergebnisse für diese Fahrt zurückgegriffen werden kann. Beispielsweise bräuchten die Parameter für die Prognosemodelle nicht immer wieder neu berechnet werden, sondern bräuchten nur geupdatet werden.




Abbildung 2.41: Visualisierung von Beispieltestfahrten. Teil 1/2




Abbildung 2.42 Visualisierung von Beispieltestfahrten. Teil 2/2




Abbildung 2.43: Vergleich der Reichweiteschätzungen




Abbildung 2.44: Vergleich der Dauern der geplanten Fahrten mit den tatsächlichen Fahrten

R7.2.1 Onlinepräsenz

Zur Außendarstellung des d-E-mand Projektes wurde eine Website von den PROJEKTIONISTEN implementiert, die die wesentlichen Inhalte des Projektes zusammenfasst. Die Website ist unter der Adresse <https://www.d-e-mand.org> zu erreichen.

Die Website ist in die Bereiche „Ziele“, „Team“ und „Arbeit“ unterteilt. Abbildung 2.45 zeigt die Landeansicht, die auch gleichzeitig die Ziele beschreibt. Abbildung 2.46 zeigt die Teamansicht, die die Partner des Projektkonsortiums zusammenfasst während Abbildung 2.47 während die Arbeitsansicht den Nutzen von d-E-mand für wesentliche Stakeholder darstellt.



Abbildung 2.45: Lande- und Zielansicht der d-E-mand Website




Abbildung 2.46: Teamansicht der d-E-mand Website




Abbildung 2.47: Arbeitsansicht der d-E-mand Website

R7.2.2 Bericht Öffentlichkeitsarbeit

Im Laufe des d-E-mand Projektes wurden zahlreiche Tätigkeiten im Bereich der Öffentlichkeitsarbeit durchgeführt. Die wesentlichen Tätigkeiten umfassen dabei:

- Vorträge auf relevanten Konferenzen und Präsenz bei Netzwerktreffen.
- Wissenschaftliche Publikationen

Vorträge auf relevanten Konferenzen und Präsenz bei Netzwerktreffen

Die in d-E-mand laufenden Arbeiten und erzielten Ergebnisse wurden stetig auf relevanten Fachkonferenzen und Netzwerktreffen vorgestellt. Insgesamt wurden Vorträge auf 12 verschiedenen wissenschaftlichen Konferenzen gehalten. Weiterhin wurde an besonders relevanten Netzwerktreffen, wie dem Symposium Intelligente Mobilität 2020¹⁴ in Hannover teilgenommen. Schließlich wurden d-E-mand Ergebnisse dem niedersächsischen Ministerpräsidenten Stephan Weil vorgestellt.

Wissenschaftliche Publikationen:

Während des d-E-mand-Projekts konnten insgesamt 17 wissenschaftliche Publikationen wie Konferenzbeiträge oder Journalartikel in internationalen Top-Konferenzen veröffentlicht werden. Herauszuheben sind insbesondere folgende Publikationen:

Sao, Ashutosh, Nicolas Tempelmeier and Elena Demidova. **“Deep Information Fusion for Electric Vehicle Charging Station Occupancy Forecasting.”** 2021 IEEE International Intelligent Transportation Systems Conference (ITSC). 2021

In diesem Paper wird beschrieben, wie mittels Deep-Learning-Algorithmen der Belegungsgrad von Ladestationen prognostiziert werden kann.

Leonie von Wahl, Nicolas Tempelmeier, Ashutosh Sao, and Elena Demidova. **Reinforcement Learning-based Placement of Charging Stations in Urban Road Networks.** In Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD). 2022.

In diesem Paper wird ein Reinforcement-Learning-Modell vorgestellt, das die Positionierung von Ladestationen innerhalb eines städtischen Straßennetzes optimiert.

Leonie von Wahl, Clara Mautsch, Stefan Ladwig, Michael Nolting, and Nicolas Tempelmeier. **Towards Data-Driven Planning of Mobile Charging Infrastructure for Electric Vehicles.** In Proceedings of the 1st ACM SIGSPATIAL Workshop on Sustainable Mobility (SuMob). 2023

In diesem Paper werden die Ergebnisse der Pilotierung der d-E-mand B2B-Anwendung wissenschaftlich diskutiert.

¹⁴ <https://sim2020.l3s.uni-hannover.de>

2.2. Wichtigste Positionen des zahlenmäßigen Nachweises

Tabelle 2.6: zahlenmäßiger Nachweis Teilvorhaben Volkswagen AG

Position	Benennung im Antrag (AZK/AZA)	Verwendung
0813	Material	Beschaffung von Hardware zur Entwicklung des Prototyps für den Sensoraufbau MaaS/TaaS. Die Beschaffung der Hardware konnte günstiger als geplant durchgeführt werden.
0837	Personal	Personal zur Koordination des Verbundprojektes und zur Bearbeitung der Arbeitspakete.
0838	Reisekosten	Geplant waren Reisen zu Workshops im Projektverbund sowie der Besuch von relevanten Netzwerktreffen, Konferenzen und Statusseminaren. Durch die Covid-19 fanden weniger Reisen als geplant statt.
0847	vorhabenspezifische Abschreibungen	Zur praktischen Evaluierung des Sensoraufbaus MaaS/TaaS wurde ein Lastenfahrzeug beschafft.
0850	Sonstige unmittelbare Vorhabenskosten	Es konnte auf die Nutzung von Cloud-Servern zugunsten von vorhandenen on-premise Servern verzichtet werden.

Tabelle 2.7: zahlenmäßiger Nachweis Teilvorhaben Gottfried Wilhelm Leibniz Universität Hannover

Position	Benennung im Antrag (AZK/AZA)	Verwendung
0812	Beschäftigte E12-E15	Finanzierung von wissenschaftlichen Mitarbeitern zur Durchführung der Projektaufgaben und Erreichung der Projektziele.
0822	Beschäftigungsentgelte	Finanzierung von studentischen Hilfskräften als Hilfwissenschaftler zur Unterstützung verschiedener Implementierungsaufgaben.
0843	Sonstige allg. Verwaltungsausgaben	Finanzierung von Open-Access-Gebühren von Projektpublikationen.
0846	Dienstreisen	Finanzierung diverser Konferenzteilnahmen zur Projektdissemination und Vorstellung von Publikationen sowie Finanzierung der Teilnahme und Ausrichtung von Konsortialtreffen.
0850	Gegenstände über 410 / 400 €	Einkauf verschiedener Datensätze (GPS-Positionsdaten von Fahrzeugen und Fahrzeugmeldestatistiken) und Finanzierung eines Servers zur Durchführung projektrelevanter Berechnungen.

Tabelle 2.8 zahlenmäßiger Nachweis Teilvorhaben PROJEKTIONISTEN GmbH

Position	Benennung im Antrag (AZK/AZA)	Verwendung
0812	Personal	Bearbeitung der jeweiligen Arbeitstakte.

Tabelle 2.9: zahlenmäßiger Nachweis Teilvorhaben Fraunhofer IVI

Position	Benennung im Antrag (AZK/AZA)	Verwendung
0837	Personal	Die Mittel in der Position 0837 wurden verwendet, um die wissenschaftlich-technischen Arbeiten entsprechend der VHB/TVB zu bearbeiten.
0838	Reisekosten	Die Mittel in der Position 0838 wurden verwendet, um an den Projekttreffen in Hannover teilzunehmen (Reisekosten und Übernachtungen).

2.3. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Das Projektteam hatte sehr anspruchsvolle, innovative und zukunftsweisende Zielstellungen formuliert. Um diese Ziele zu erreichen war ein F&E Netzwerk in Kooperation aller Verbundpartnern als Mischung aus Wirtschaft und Wissenschaft von Nöten. Interdisziplinäre Expertisen waren zu bündeln und nur in dieser kooperativen Form war ein Ergebnis in dargestellter Qualität zu erwarten.

Teilvorhaben Konsortialführer Volkswagen AG:

Ohne die Förderung durch das Bundesministerium wäre das geplante Vorhaben aufgrund des wirtschaftlichen Risikos von der Volkswagen AG nicht durchgeführt wurden, zumal das notwendige Wissen in diesem Bereich nicht in ausreichendem Maße intern vorhanden war. Die Zusammenarbeit mit den Projektpartnern war somit unabdingbar. Insbesondere der im Projekt entwickelte Sensoraufbau mit skalierbarer Hardware war mit einem hohen Risiko belastet.

Aus wirtschaftlicher Sicht ist es erstrebenswert, sich im Bereich Elektromobilität eine technologische Marktführerschaft im Datenbereich zu sichern, um so mittelfristig Arbeitsplätze innerhalb der Wertschöpfungskette der neuen Technologien zu schaffen. Diese Bestrebungen zahlen direkt auf die förderpolitischen Ziele des Technologieprogrammes IKT für Elektromobilität der Bundesregierung ein. Die in d-E-mand geleistete Arbeit und gesammelte Erfahrung zur Erhebung und Verarbeitung der relevanten Daten stellt hierfür einen wertvollen Grundstein da, der auf anderem Wege nur schwer zu erreichen gewesen wäre.

Teilvorhaben Gottfried Wilhelm Leibniz Universität Hannover:

Straßen, Bürgersteige, Wege oder öffentliche Räume im Allgemeinen sind Orte, an denen die Vor- und Nachteile des städtischen Lebens zu sich überschneidenden Herausforderungen führen. Öffentlicher Raum ist durch die gemeinsame Nutzung durch verschiedene Akteure gekennzeichnet. Da die Anforderungen an die Städte zunehmen, wird die gemeinsame Nutzung zu einem Wettbewerb um diese begrenzte Ressource. Um dieser Entwicklung zu begegnen, ist es entscheidend, den öffentlichen Raum selbst und seine Nutzung zu quantifizieren. Dazu ist eine kontinuierliche Erfassung von Umweltdaten mit Fahrzeugsensoren und eine anschließende Anwendung eines Deep-Learning-Modells erforderlich, das auf die semantische Segmentierung von mobilen Kartendaten zugeschnitten ist. Die segmentierten Daten wurden aggregiert, um räumliche und statistische Nutzungsinformationen zu gewinnen.

Der öffentliche Raum zeichnet sich durch die Zugänglichkeit für alle Nutzer mit möglichst wenig Einschränkung aus. Diese offene Definition ist in dicht besiedelten städtischen Räumen notwendig und hat den Vorteil der Flexibilität und der Maximierung der Nutzung. Verschiedene Arten von Nutzern (privat, gewerblich, staatlich) nutzen öffentliche Räume im Rahmen unterschiedlicher Anwendungen (Verkehr, gewerbliche Tätigkeit, Erholung usw.). Die Nachteile der gemeinsamen Nutzung sind der Wettbewerb um den begrenzten Raum und die daraus resultierende schlechte Planbarkeit (situativ für die Nutzer, global für die Verwaltung). Die Quantifizierung des verfügbaren Raums im Sinne einer Kartierung und dynamischen Erfassung der zeitlichen Nutzung eröffnet der Verwaltung und den Nutzern die Möglichkeit,

die oben beschriebenen Nachteile zu kompensieren und das Nutzungspotenzial zu erhöhen. Das Problem der Identifizierung von Parkraumstatistiken wurde bereits mit klassischen maschinellen Lernverfahren zur semantischen Segmentierung der Punktwolken angegangen. In unserem Ansatz führen wir die semantische Segmentierung mit Hilfe eines DL-Modells durch. Dies macht den Ansatz robuster und flexibler für die Untersuchung verschiedener Objekttypen (semantische Klassen), was uns auch erlaubt, weitere Analysen durchzuführen, z.B. der Fußgänger, Radfahrer. Die Identifikation von eindeutigen Objekten innerhalb einer semantisch segmentierten Punktwolke (oder Bild) ist die Aufgabe der Instanzsegmentierung. Diese Art von Aufgabe kann mit maschinellen (Deep) Learning Ansätzen angegangen werden. In Rahmen dieses Projekts wurde eine Pipeline entwickelt, die es erlaubt MMS-Daten semantisch zu segmentieren und anschließend relevanten Objekten (Parkplätze in diesem Fall) zu kartieren.

Um eine Methode für die optimale Platzierung mobiler Ladestationen in verschiedenen Regionen zu entwickeln (R3.2), war eine genaue Schätzung der Nachfrage in den entsprechenden Regionen erforderlich. Um eine präzise Schätzung zu erhalten, haben wir aktuelle Machine Learning-Techniken und Deep Learning eingesetzt.

Die Genauigkeit solcher Modelle hängt jedoch stark von der Verfügbarkeit und Qualität der Daten ab. Hierzu war zuerst eine Analyse von Verkehrsdaten hinsichtlich ihrer Eignung als Annäherung an die Ladebedarfe notwendig (R2.4). Um zu vermeiden, dass Ladestationen in der Nähe bestehender Infrastrukturen platziert werden, war es außerdem notwendig, Informationen über bestehende CS zu sammeln, für die Webdaten wichtig sind (R2.4). Um diese verschiedenen Datenquellen effektiv zu integrieren und zu nutzen, war ein Datenmodell erforderlich, das sie effektiv integriert (R3.1).

Abgesehen von diesen technischen Anforderungen war es für die Entwicklung und Etablierung gesamtgesellschaftlich akzeptierter Methoden unerlässlich, die Bürger in die Lösung einzubeziehen (R2.5).

Teilvorhaben PROJEKTIONISTEN GmbH:

Durch die gezielte Zusammenarbeit mit dem Konsortium konnten die definierten Ziele effizient erreicht und signifikante Fortschritte für zukünftige Themen erzielt werden. Die Ergebnisse sind nicht nur qualitativ hochwertig, sondern auch wiederverwendbar, da dies jederzeit als sehr hohes Ziel im Blick behalten wurde. Auch die notwendigen Anpassungen an die Herausforderungen der Corona-Pandemie konnten schnell umgesetzt werden, sodass die Produktivität hochgehalten wurde.

Teilvorhaben Fraunhofer IVI:

Die geleistete Arbeit im Rahmen dieses Projekts wurde mit größter Sorgfalt und unter Berücksichtigung der Projektziele durchgeführt. Die folgenden Punkte illustrieren, wie die erbrachten Leistungen in vollem Umfang angemessen und notwendig waren, um diese Ziele zu erreichen: Die im Projekt verfolgten Ziele wurden von Anfang an präzise definiert und auf die Förderziele abgestimmt. Die Ressourcen, seien es finanzielle, personelle oder materielle,

wurden effizient und gezielt eingesetzt. Die Ergebnisse umfassen die Services Trip Monitoring und RangeEstimation sowie die Konzepte für die Anbindung an einen Data Space. Sie legen den Grundstein für zukünftige Entwicklungen in diesem Bereich. Insgesamt waren die im Rahmen dieses Projekts erbrachten Leistungen nicht nur angemessen, um die gesteckten Ziele zu erreichen, sondern auch von großer Bedeutung für die Förderziele des Bundesministeriums für Wirtschaft und Energie. Die sorgfältige Planung und Ausführung unserer Arbeit haben dazu beigetragen, die gestellten Erwartungen zu erfüllen und den beabsichtigten gesellschaftlichen Nutzen zu maximieren.

2.4. Voraussichtlicher Nutzen, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans

Tabelle 2.10: Verwertung Teilvorhaben Volkswagen AG

Projektergebnis/ Inhalt	Nutzen/ Verwertung
Erkenntnis des Labelingbedarfs in AP 2.3	Sicherung von 5 Arbeitsplätzen innerhalb der neuen Technologien über Projektergebnisse aus dem d-E-mand Projekt
Publikationen	Insgesamt 4 Veröffentlichungen auf internationalen Topkonferenzen und Fachbänden zur Öffentlichkeitsarbeit und Steigerung der Sichtbarkeit der Themen.
Vorträge	Vorstellung von d-E-mand Ergebnissen unter anderem vor dem Volkswagen AG Konzern Vorstand und Ministerpräsident Stephan Weil zur Öffentlichkeitsarbeit und Steigerung der Sichtbarkeit der Themen.
Erfahrungen in Erfassung, Verarbeitung und Visualisierung von Lidar / Laserscanner Daten	Transfer von Wissen zur Implementierung von Verarbeitungspipelines spezialisierter Datenformat für die ADMT GmbH (Volkswagen Nutzfahrzeuge Tochter Autonomous Driving MaaS/TaaS)
Erfasste Lidar und Kamera Daten	Einfacher Zugang zu Proxy-Testdaten aus Datenfahrrad für die ADMT-Cloud (Volkswagen Nutzfahrzeuge Tochter Autonomous Driving MaaS/TaaS)

Tabelle 2.11: Verwertung Teilvorhaben Gottfried Wilhelm Leibniz Universität Hannover

Projektergebnis/ Inhalt	Nutzen/ Verwertung
Publikationen	Insgesamt 15 Veröffentlichungen auf internationalen Topkonferenzen und Fachbänden zur Öffentlichkeitsarbeit und Steigerung der Sichtbarkeit der Themen.
Datenserver	Fortlaufende Speicherung von MMS-Daten
Analyse-Pipeline	Ergebnisse der Pipeline erlauben weiterführende Untersuchungen der Forschungsansätze im Bereich der Lokalisation, Visualisierung und Kartierung. Die Weiterentwicklung der Pipeline ermöglicht es, weitere Objektklassen zu identifizieren und zu kartieren.

Tabelle 2.12: Verwertung Teilvorhaben PROJEKTIONISTEN GmbH

Projektergebnis/ Inhalt	Nutzen/ Verwertung
Digitale Geschäftsmodelle	Umsetzung der erarbeiteten Geschäftsmodelle, Akquise weiterer Kunden in Zusammenarbeit mit unseren Partnern und assoziierten Partner (bspw. im Umfeld von Stadtwerken und Energieversorgern).
d-E-mand Plattform, d-E-mand Dashboard, d-E-mand App	Überführung der Entwicklungen in den Live-Betrieb bei den Partnern und assoziierten Partnern.
d-E-mand Plattform, d-E-mand Dashboard, d-E-mand App	Weiterentwicklung und Finetuning der entwickelten Module im Rahmen des 1KLANG Mobilitätsbaukastens. Akquise von Bestandskunden und ggf. neuen Kunden die Elemente der E-Mobilität in ihren Anwendungen mit Hilfe der d-E-mand Entwicklungen abbilden möchten.

Tabelle 2.13: Verwertung Teilvorhaben Fraunhofer IVI

Projektergebnis/ Inhalt	Nutzen/ Verwertung
Services Trip Monitoring und RangeEstimation	Die entwickelten und als Dienste aufgesetzten Services bieten zusammen mit den Lessons Learned eine gute Basis für die Erforschung und Entwicklung zukünftiger Technologien.
IDS-Komponenten	Der entwickelte Connector steht als Open Source zur Verfügung und kann zusammen mit dem Integrationskonzept zur Verknüpfung mit weiteren IDS-fähigen Datenplattformen in nachfolgenden Projekten eingesetzt werden.

2.5. Während der Durchführung des Vorhabens dem ZE bekannt gewordenen Fortschritts auf dem Gebiet des Vorhabens bei anderen Stellen

Teilvorhaben Konsortialführer Volkswagen AG:

Keine bekannten Fortschritte von anderen Stellen.

Teilvorhaben Gottfried Wilhelm Leibniz Universität Hannover:

Keine bekannten Fortschritte von anderen Stellen.

Teilvorhaben PROJEKTIONISTEN GmbH:

Keine bekannten Fortschritte von anderen Stellen.

Teilvorhaben Fraunhofer IVI:

Keine bekannten Fortschritte von anderen Stellen.

2.6. Erfolgte oder geplanten Veröffentlichungen des Ergebnisses nach Nr. 11 der Nebenbestimmungen

Tabelle 2.14: Veröffentlichungen Teilvorhaben Volkswagen AG

Titel	Datum	Ort (Zeitungsnamen, ISBN, ggf. Link etc.)	Inhalt (kurz)
Environmental Data Collection as a Byproduct for Autonomous Ride-Hailing Services	2021	IEEE International Intelligent Transportation Systems Conference	In dem Paper werden Strategien zu dem Routing von Transportation-as-a-Service Flotten vorgestellt, um eine Abdeckung des Straßennetzes zur Datensammlung zu ermöglichen.
Reinforcement Learning-based Placement of Charging Stations in Urban Road Networks	2022	ACM SIGKDD Conference on Knowledge Discovery and Data Mining	Es wird ein Reinforcement Learning Ansatz vorgestellt, um Ladeinfrastruktur bedarfsgerecht in urbanen Straßennetzen zu platzieren.,
MetaCitta: Deep Meta-Learning for Spatio-Temporal Prediction Across Cities and Tasks	2023	Pacific-Asia Conference on Knowledge Discovery and Data Mining	Es wird eine Methode vorgestellt, um Modelle für räumlich-zeitliche Prognosen zwischen unterschiedlichen Städten zu übertragen.
Towards Data-Driven Planning of Mobile Charging Infrastructure for Electric Vehicles	13. 11.2023	1st ACM SIGSPATIAL Workshop on Sustainable Mobility (SuMob 2023)	Analyse und Diskussion der Ergebnisse aus der d-E-mand Pilotierung zur datenbasierten Platzierung von mobiler Ladeinfrastruktur im Kontext von Großveranstaltungen.

Tabelle 2.15: Veröffentlichungen Teilvorhaben Gottfried Wilhelm Leibniz Universität Hannover

Titel	Datum	Ort (Zeitungsnamen, ISBN, ggf. Link etc.)	Inhalt (kurz)
TA-Dash: An Interactive Dashboard for Spatial-Temporal Traffic Analytics.	2020	ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. Demonstrator	TA-Dash ist ein Demonstrator zur visuellen Integration datenbasierter Verkehrsanalyse-Algorithmen. Im Demonstrator werden Auswirkungen von Veranstaltungen auf den Straßenverkehr sowie gegenseitige Abhängigkeiten von Straßen im Straßennetz dargestellt.
Linking OpenStreetMap with knowledge	2021	Future Generation Computer	Die Repräsentation von Geo-Entitäten in verschiedenen Datenquellen unterscheidet sich oft in Bezug auf Inhalt und

graphs — Link discovery for schema-agnostic volunteered geographic information		Systems, Special Issue on Machine Learning and Knowledge Graphs, Elsevier	Datenstruktur. In diesem Artikel werden zwei der wichtigsten Datenquellen für Geo-Entitäten, OpenStreetMap und Wikidata, verknüpft, um die Verfügbarkeit von Geo-Informationen zu erhöhen.
Mining Topological Dependencies of Recurrent Congestion in Road Networks	2021	ISPRS International Journal of Geo-Information	Der Artikel beschreibt einen neuartigen Datamining-Algorithmus, um gegenseitige Abhängigkeiten von Straßenabschnitten innerhalb des Straßennetzes zu identifizieren.
Deep Information Fusion for Electric Vehicle Charging Station Occupancy Forecasting	2021	IEEE International Intelligent Transportation Systems Conference	Das Paper beschreibt einen Deep Learning Ansatz, um mittels Zeitreihenanalyse den Belegungszustand von Ladeinfrastruktur vorherzusagen.
An Adaptive Clustering Approach for Accident Prediction	2021	IEEE International Intelligent Transportation Systems Conference	In dem Paper werden Verkehrsdaten genutzt, um die Wahrscheinlichkeit von Unfällen in Abhängigkeit der geographischen Region zu prognostizieren.
Towards Neural Schema Alignment for OpenStreetMap and Knowledge Graphs	2021	International Semantic Web Conference	In diesem Paper wird untersucht, wie das Datenschema von Geo-Entitäten in verschiedenen Datenquellen, insbesondere Wikidata und OpenStreetMap, mit Hilfe von künstlicher Intelligenz vereinheitlicht werden kann.
GeoVectors: A Linked Open Corpus of OpenStreetMap Embeddings on World Scale	2021	International Conference on Information and Knowledge Management	In diesem Paper werden maschinenlesbare Repräsentationen von Geo-Entitäten für die gesamte Welt zur Verfügung gestellt. Mit dieser Repräsentation können beispielsweise KI-Algorithmen trainiert werden.
Ovid: A Machine Learning Approach for Automated Vandalism Detection in OpenStreetMap	2021	ACM SIGSpatial International Conference on Advances in Geographic Information Systems. Poster	Es wird ein neuer Ansatz vorgestellt, um böswillige Manipulation, sogenannter Datenvandalismus, in OpenStreetMap zu erkennen.

Determination of Parking Space and its Concurrent Usage Over Time Using Semantically Segmented Mobile Mapping Data	2021	The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences	Es werden Laserscan-Daten analysiert, um nicht-kartierte Parkplatzpositionen an Straßenrändern zu identifizieren.
Creating knowledge graphs for geographic data on the web	2022	SIGWeb newsletter	Zusammenfassung von Methoden, um geographische Wissensgraphen zu erstellen.
Attention-Based Vandalism Detection in OpenStreetMap	2022	The ACM Web Conference	Es wird ein neuer Ansatz detailliert beschrieben, um böswillige Manipulation, sogenannter Datenvandalismus, in OpenStreetMap zu erkennen.
Reinforcement Learning-based Placement of Charging Stations in Urban Road Networks	2022	ACM SIGKDD Conference on Knowledge Discovery and Data Mining	Es wird eine Reinforcement Learning Ansatz vorgestellt, um Ladeinfrastruktur bedarfsgerecht in urbanen Straßennetzen zu platzieren.
W-trace: robust and effective watermarking for GPS trajectories	2022	ACM SIGSpatial International Conference on Advances in Geographic Information Systems	In dem Paper wird eine Methode vorgestellt, um GPS-Trajektorien mit einer digitalen Wassermarke zu versehen und so wiedererkennbar zu machen.
MetaCitta: Deep Meta-Learning for Spatio-Temporal Prediction Across Cities and Tasks	2023	Pacific-Asia Conference on Knowledge Discovery and Data Mining	Es wird eine Methode vorgestellt, um Modelle für räumlich-zeitliche Prognosen zwischen unterschiedlichen Städten zu übertragen.
Road Network Representation Learning with Vehicle Trajectories	2023	Pacific-Asia Conference on Knowledge Discovery and Data Mining	Es wird eine Methode vorgestellt, um Repräsentation von Fahrzeug GPS-Trajektorien zu lernen. Die Repräsentation können von KI-Algorithmen für weiterführende Prognosen genutzt werden.

Tabelle 2.16: Veröffentlichungen Teilvorhaben PROJEKTIONISTEN GmbH

Titel	Datum	Ort (Zeitungsnamen, ISBN, ggf. Link etc.)	Inhalt (kurz)
Towards Data-Driven Planning of Mobile Charging Infrastructure for Electric Vehicles	13. 11.2023	1st ACM SIGSPATIAL Workshop on Sustainable Mobility (SuMob 2023)	Analyse und Diskussion der Ergebnisse aus der d-E-mand Pilotierung zur datenbasierten Platzierung von mobiler Ladeinfrastruktur im Kontext von Großveranstaltungen.

Tabelle 2.17: Veröffentlichungen Teilvorhaben Fraunhofer IVI

Titel	Datum	Ort (Zeitungsnamen, ISBN, ggf. Link etc.)	Inhalt (kurz)

Literatur

- [1] Electric Vehicle Platform Strategy of Global Passenger Vehicle OEMs, Forecast to 2025, Frost & Sullivan, 2017.
- [2] „Forschungsüberblick Netzintegration Elektromobilität,“ FGH e.V., 2018.
- [3] H. Shareef, M. M. Islam und A. Mohamed, „A review of the stage-of-the-art charging technologies, placement methodologies, and impacts of electric vehicles,“ *Renewable and Sustainable Energy Reviews*, pp. 403-420, 2016.
- [4] Y. Xiang, J. Liu, R. Li, F. Li, C. Gu und S. Tang, „Economic planning of electric vehicle charging stations considering traffic constraints and load profile templates,“ *Applied Energy*, pp. 647-659, 2016.
- [5] X. Dong, Y. Mu, H. Jia, J. Wu und X. Yu, „Planning of Fast EV Charging Stations on a Round Freeway,“ *IEEE Transactions on Sustainable Energy*, pp. 1452-1461, 2016.
- [6] D. Gavalas, K. Giannakopoulou, V. Kasapakis, D. Kehagias, C. Konstantopoulos, S. Kontogiannis, D. Kypriadis, G. Pantziou, A. Paraskevopoulos und C. Zaroliagis, „Renewable Mobility in Smart Cities: Cloud-Based Services,“ in *IEEE Symposium on Computers and Communications*, 2018.
- [7] U. Feuerhake, O. Wage, M. Sester, N. Tempelmeier, W. Nejdil und E. Demidova, „Identification of similarities and prediction of unknown features in an urban street network,“ in *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-4*, 2018.
- [8] N. Tempelmeier, Y. Rietz, I. Lishchuk, T. Krügel, O. Mumm, V. M. Carlow, S. Dietze und E. Demidova, „Data4UrbanMobility: Towards Holistic Data Analytics for Mobility Applications in Urban Regions,“ in *Companion Proceedings of The 2019 World Wide Web Conference*, 2019.
- [9] C. Brenner, „Scalable Estimation of Precision Maps in a MapReduce Framework,“ in *Proceedings of the 24th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2016.
- [10] T. Peters und C. Brenner, „Automatic Generation of Large Point Cloud Training Datasets Using Label Transfer,“ in *39. Wissenschaftlich-Technische Jahrestagung der DGPF e.V.*, 2019.
- [11] H. Cheng und M. Sester, „Modeling Mixed Traffic in Shared Space Using LSTM with Probability Density Mapping,“ in *21st International Conference on Intelligent Transportation Systems*, 2018.

- [12] F. Bock, J. Liu und M. Sester, „Learning On-Street Parking Maps from Position Information of Parked Vehicles,“ in *Geospatial Data in a Changing World*, 2016.
- [13] Y. Feng und M. Sester, „Extraction of pluvial flood relevant volunteered geographic information (VGI) by deep learning from user generated texts and photos,“ *ISPRS International Journal of Geo-Information*, 2018.
- [14] C. Yang und G. Gidófalvi, „Fast map matching, an algorithm integrating hidden Markov model with precomputation,“ *International Journal of Geographical Information Science*, 2018.
- [15] Y. Lou, C. Zhang, Y. Zheng, X. Xie, W. Wang und Y. Huang, „Map-matching for low-sampling-rate GPS trajectories,“ in *Proceedings of the 17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2009.
- [16] R. Dadwal, T. Funke und E. Demidova, „An Adaptive Clustering Approach for Accident Prediction,“ in *IEEE International Intelligent Transportation Systems Conference*, 2021.
- [17] N. Tempelmeier, U. Feuerhake, O. Wage und E. Demidova, „Mining Topological Dependencies of Recurrent Congestion in Road Networks,“ *ISPRS International Journal of Geo-Information*, 2021.
- [18] A. Dsouza, N. Tempelmeier und E. Demidova, „Towards Neural Schema Alignment for OpenStreetMap and Knowledge Graphs,“ in *The Semantic Web - 20th International Semantic Web Conference*, 2021.
- [19] N. Tempelmeier, S. Gottschalk und E. Demidova, „GeoVectors: A Linked Open Corpus of OpenStreetMap Embeddings on World Scale,“ in *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*, 2021.
- [20] N. Tempelmeier und E. Demidova, „Attention-Based Vandalism Detection in OpenStreetMap,“ in *Proceedings of the ACM Web Conference*, 2022.
- [21] A. Sao, N. Tempelmeier und E. Demidova, „Deep Information Fusion for Electric Vehicle Charging Station Occupancy Forecasting,“ in *IEEE International Intelligent Transportation Systems Conference*, 2021.
- [22] A. Sao, S. Gottschalk, N. Tempelmeier und E. Demidova, „MetaCitta: Deep Meta-Learning for Spatio-Temporal Prediction Across Cities and Tasks,“ in *Advances in Knowledge Discovery and Data Mining, PAKDD*, 2023.
- [23] L. von Wahl, N. Tempelmeier, A. Sao und E. Demidova, „Reinforcement Learning-Based Placement of Charging Stations in Urban Road Networks,“ in *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 2022.

- [24] A. Leichter, U. Feuerhake und M. Sester, „Determination of parking space and its concurrent usage over time using semantically segmented mobile mapping data,“ *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, 2021.
- [25] L. Mao, A. Fotouhi, N. Shateri und N. Ewin, „A multi-mode electric vehicle range estimator based on driving pattern recognition,“ *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 2022.
- [26] P. Czioska, D. C. Mattfeld und M. Sester, „GIS-based identification and assessment of suitable meeting point locations for ride-sharing,“ *Transportation Research Procedia*, 2017.
- [27] U. Feuerhake, C. Kuntzsch und M. Sester, „Finding interesting places and characteristic patterns in spatio-temporal trajectories,“ in *Proceedings of the 8th International Symposium on Location-Based Services*, 2011.
- [28] A. Y. S. Lam, L. Yiu-Wing und X. Chu, „Electric Vehicle Charging Station Placement: Formulation, Complexity, and Solutions,“ *IEEE Transactions on Smart Grid*, p. 2846–2856, 2014.

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht	
3. Titel d-E-mand: Vorhersage von Ladebedarf bei Elektromobilität als Business Enabler		
4. Autor(en) [Name(n), Vorname(n)] Aykac, Cana Dumschat, Anna Valeria Feuerhake, Udo Gottschalk, Simon Hagedorn, Anika Henke, Nils Leichter, Artem Löhdefink, Martin Mautsch, Clara Meyer, Niklas Nolting, Michael Pretzsch, Sebastian Sao, Ashutosh Tempelmeier, Nicolas Von Wahl, Leonie Wonsak, Shimon	5. Abschlussdatum des Vorhabens 30.06.2023	6. Veröffentlichungsdatum 01.01.2024
	7. Form der Publikation Bericht	
	9. Ber. Nr. Durchführende Institution	
8. Durchführende Institution(en) (Name, Adresse) Volkswagen AG, Nutzfahrzeuge, Digital Services & Data Analytics Mecklenheidestraße 74, 30419 Hannover Gottfried Wilhelm Leibniz Universität Hannover, Forschungszentrum L3S Institut für Kartographie und Geoinformatik Appelstr. 9a, 30167 Hannover PROJEKTIONISTEN GmbH Schaufelder Straße 11, 30167 Hannover Fraunhofer-Gesellschaft zur Förderung der Angewandten Wissenschaften e.V. Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI Zeunerstraße 38, 01069 Dresden	10. Förderkennzeichen 01ME19009	
	11. Seitenzahl 104	
	13. Literaturangaben 28	
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Energie (BMWi) 11019 Berlin	14. Tabellen 18	
	15. Abbildungen 48	
16. Zusätzliche Angaben		
17. Vorgelegt bei (Titel, Ort, Datum)		

18. Kurzfassung

Die Elektromobilität ist für die Einhaltung der globalen Klimaschutzziele alternativlos. Im Zuge der Elektrifizierung und Digitalisierung des Verkehrs wird zudem die Lebensqualität in urbanen Räumen steigen. Dies geschieht durch die Reduzierung von Abgasen, Lärm- und Feinstaubbelastung sowie Entlastung der Verkehrsinfrastruktur mit dem Zuwachs von E-Sharing-Angeboten wie Mobility / Transportation as a Service (MaaS / TaaS).

Das Ziel des Projekts war die Schaffung einer Geschäftsgrundlage für KMUs und Start-Ups für neuartige Dienstleistungen bezogen auf die Bedienung von erhöhtem räumlich-zeitlichen Ladebedarf von Elektrofahrzeugen und Eröffnung neuer Geschäftsfelder in diesem Bereich. Darüber hinaus sollten für Großunternehmen, wie Netzbetreiber und Ladestationshersteller, entsprechende Analytics-Schnittstellen zur Bedarfsermittlung und Optimierung der Energieversorgung geschaffen werden.

In d-E-mand wurden die dazu notwendigen Datenbasierten Algorithmen und Services in Form von Machine Learning Algorithmen und verschiedenen Apps geschaffen. Dabei wurden sowohl B2B und B2C Szenarien beachtet. Die entwickelten Algorithmen können zur Ladebedarfsprognose und zur Platzierung von Ladeinfrastruktur genutzt werden.

Die entwickelten Komponenten stellen eine vielversprechende Grundlage für die Operationalisierung für Dienstleistung zur bedarfsgerechten Platzierung von Ladeinfrastruktur für Elektrofahrzeuge dar.

19. Schlagwörter

Ladeinfrastruktur, E-Mobilität, Daten, Machine Learning

20. Verlag

-

21. Preis

0€

Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Report
3. title d-E-mand: Vorhersage von Ladebedarf bei Elektromobilität als Business Enabler	
4. author(s) (family name, first name(s)) Aykac, Cana Dumschat, Anna Valeria Feuerhake, Udo Gottschalk, Simon Hagedorn, Anika Henke, Nils Leichter, Artem Löhdefink, Martin Mautsch, Clara Meyer, Niklas Nolting, Michael Pretzsch, Sebastian Sao, Ashutosh Tempelmeier, Nicolas Von Wahl, Leonie Wonsak, Shimon	5. end of project June 30 th 2023
	6. publication date January 1 st 2024
	7. form of publication Report
8. performing organization(s) (name, address) Volkswagen AG, Nutzfahrzeuge, Digital Services & Data Analytics Mecklenheidestraße 74, 30419 Hannover Gottfried Wilhelm Leibniz Universität Hannover, Forschungszentrum L3S Institut für Kartographie und Geoinformatik Appelstr. 9a, 30167 Hannover PROJEKTIONISTEN GmbH Schaufelder Straße 11, 30167 Hannover Fraunhofer-Gesellschaft zur Förderung der Angewandten Wissenschaften e.V. Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI Zeunerstraße 38, 01069 Dresden	9. originator's report no.
	10. reference no. 01ME19009
	11. no. of pages 104
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Energie (BMWi) 11019 Berlin	13. no. of references 28
	14. no. of tables 18
	15. no. of figures 48
16. supplementary notes	
17. presented at (title, place, date)	

18. abstract

The adoption of electric vehicle is a key success factor for reaching the global climate protection goals. Electrifying cars will also lead to a general better life quality of life in urban areas through the reduction of emissions and noise pollutions. Further, shared mobility services such as mobility as a service and transportation as a service are particularly likely to be adopted for electric vehicles.

This project aimed to create a business foundation for small and medium-sized enterprises (SMEs) and startups offering innovative services related to charging electric vehicles, opening up new markets, and creating demand-based analytics interfaces for energy supply optimization.

To achieve this goal, data-driven algorithms and services were developed, i.e., machine learning techniques and various apps. Both B2B and B2C scenarios were considered. The developed algorithms can predict charging needs and optimize the placement of charging infrastructure. The developed components provide a promising basis for operationalizing services related to the demand-based placing charging infrastructure for electric vehicles.

19. keywords

Electric vehicle charging infrastructure, data, machine learning

20. publisher

-

21. price

0€