

Methodik zur Temporären Analyse Logistischer Systeme auf Basis von Entfernungsdaten und Methoden der Prozessklassifizierung

Methodology for temporary analysis of logistic systems based on distance data and process classification methods

*Madlin Müller
Mathias Kühn
Thorsten Schmidt*

*Professur für Technische Logistik
Institut für Technische Logistik und Arbeitssysteme
Technische Universität Dresden*

In kleinen und mittleren Unternehmen (KMU) besteht für logistische Prozesse die Herausforderung einer unvollständigen Datenbasis. KMU können nur eingeschränkt auf verfügbaren Methoden zur Datengenerierung zurückgreifen. Manuelle Methoden erfordern einen hohen Ressourcenbedarf und die generierte Datenbasis ist ungenau und subjektiv. Tracking Systeme sind kostenintensiv, unflexibel und mit hohem Installationsaufwand verbunden. Um eine fundierte Datengrundlage zu schaffen, stehen für KMU derzeit keine geeigneten Methoden zur Verfügung. Aus diesen Gründen wird eine Methodik vorgestellt, die der Zielstellung unterliegt, eine KMU-gerechte Vorgehensweise zur effizienten, temporär durchführbaren Datenerhebung und -auswertung in Produktions- und Logistiksystemen als Basis zur Prozessanalyse und -verbesserung zu entwickeln. Die Gesamtmethodik fokussiert die retrospektive Lokalisierung und Analyse von Materialflussobjekten. Die technologische Grundlage bilden auf Bluetooth Low Energy (BLE)-basierende Signaler, sogenannte Beacons, und handelsübliche Smart Mobile Devices (SMD) als Empfänger, zwischen denen Entfernungsdaten gemessen und retrospektiv Bewegungsprofile abgeleitet werden. Im Entwicklungsfokus steht eine Software-basierte Methodik. Dafür stehen die Auswahl und Implementierung von Mustererkennungsverfahren zur automatischen Prozesserkennung sowie Verfahren zur Visualisierung von relativen Entfernungsdaten im Forschungsfokus.

[Schlüsselwörter: retrospektive Lokalisierung, RSSI, Signalaufbereitung, Parametereinstellung, Maschinelles Lernen, Prozessklassifizierung]

Small and medium-sized enterprises (SMEs) face the challenge of a missing or incomplete database, especially for logistics processes. In addition, SMEs have only

limited access to currently available methods for data acquisition. Manual methods usually requires a very large amount of resources and result in a limited database. Indoor tracking systems are cost-intensive, inflexible and require a high installation effort. There are currently no suitable methods available for SMEs to create a well-founded and reliable data basis. For these reasons, a methodology is presented which is subject to the objective of developing an SME-appropriate approach for efficient, temporarily feasible data collection and evaluation in production and logistics systems as a basis for process analysis and improvement. The overall methodology focuses on the retrospective, event-based tracing and analysis of material flow objects. The technological basis are innovative BLE-based signal transmitters, so-called beacons, and commercially available Smart Mobile Devices (SMD) as receivers, between which distance data are measured and retrospectively derived movement profiles. As a basis for the interpretation of relative movements of transmitters and receivers based on the distance data, a modular software architecture is to be developed. The selection and implementation of pattern recognition methods for automatic process recognition as well as methods for the visualization of relative distance data are in the research focus.

[Keywords: event-based tracing, machine learning, process classification, parameter settings, RSSI, signal smoothing]

1 EINFÜHRUNG

Industrie 4.0 – Digitalisierung und Vernetzung, Internet der Dinge, Künstliche Intelligenz – all diese Themen sind für führende Industrieunternehmen aktuell und relevant, um wettbewerbsfähig zu bleiben. Um Arbeitsabläufe auf dem Weg zur Industrie 4.0 gestalten und optimieren zu

können, ist jedoch fundiertes Wissen und eine umfangreiche Analyse der IST-Situation von Wirkzusammenhängen zwischen existierenden Prozessen notwendig. Speziell in KMU besteht aufgrund fehlender Daten die Herausforderung, eine fundierte sowie verlässliche Grundlage für Prozessanalysen, Optimierungen und Planungen zu schaffen [GWSF17].

Key-Performance Indicators (KPIs) mit Fokus auf logistische Prozesse werden vorrangig mit manuellen Methoden (Selbstaufschreibung, Fremdbeobachtung, Multimomentaufnahmen, Soll-Ist-Vergleich mit PPS-Vorgaben) ermittelt ([Mar14]; [VDI17]). Die Anwendbarkeit dieser Methoden mit dem Ziel einer systematischen Prozessanalyse und Kenntniserwerb ist begrenzt, da sich in komplexen produktionslogistischen Systemen diverse Prozesse überlagern und somit zur Generierung einer fundierten Datenbasis ein hoher Ressourcenaufwand (Zeit, Mitarbeiter, Kosten, etc.) notwendig ist. Manuelle Methoden stehen somit im Spannungsfeld zwischen Aufwand und Genauigkeit. Datenaufnahmen erfolgen in der Praxis daher stichprobenartig und punktuell, Wirkzusammenhänge werden häufig nicht erkannt. Zudem unterliegen diese Methoden stark subjektiven Einflüssen. Werden Mitarbeiter von außen beobachtet, verändern diese nachvollziehbarerweise ihr Arbeitstempo und die Aufmerksamkeit. Aber auch Selbstaufschreibungen bzw. -beobachtungen können bewusst oder unbewusst manipuliert sein. Gleichzeitig wird dem Mitarbeiter zusätzlicher Aufwand bereitet [Mat12]. Ein weiterer Nachteil der manuellen Methoden ist die notwendige Interpretation und Abstraktion der Tätigkeiten. Ein menschlicher Beobachter kann nur das notieren, was er versteht und den richtigen Prozessschritten zuordnet (Interpretation). Ein tiefes Detailwissen ist in der Regel nicht vorhanden, da ein externer Beobachter nicht alle Prozesselemente kennen kann (Abstraktion). Informationen gehen verloren, was zu einer Verfälschung der Daten bzw. zu fehlerhaften Rückschlüssen bei deren Auswertung führen kann.

Die Gründe für die fehlende permanente digitale Datenaufnahme durch „Track and Trace-Systeme“ in KMU sind vielseitig. Neben hohen Investitionen und hohem Installationsaufwand für Systeme zur Objekt- bzw. Prozessverfolgung [Köp14], welche meist über Indoor-Lokalisierung per GPS realisiert werden, ist der Nutzen einer permanenten Datenerfassung im Vorfeld einer solchen kostenintensiven Investition auf Grund der fehlenden Prozesskenntnis für die Verantwortlichen nur schwer quantifizierbar [Gro06]. Des Weiteren sind KMU zur Bewältigung der Kundenanforderungen auf flexible und adaptive Logistik- und Produktionssysteme angewiesen, wodurch starre Systeme zur permanenten Datenerfassung (Bspw. RFID-Gate Systeme [Gir15]) auf Grund des zu hohen Installationsaufwands, sowohl zeitlich als auch monetär, nicht effizient und praktikabel sind. KMU unterliegen häufig einer hohen Prozessvarianz (heterogene Arbeitsinhalte sowie un-

regelmäßige, vielfältige Prozessfolgen) und Prozessstöranfälligkeit (Terminänderungen, Produktänderungen). Durch diese stetigen Veränderungen der Logistik- und Produktionssysteme muss die Datenerfassung permanent angepasst werden, wodurch zusätzlich hohe Betriebsaufwendungen entstehen. In diesem Zusammenhang ist der Anspruch an Datengranularität und Genauigkeit von automatisierten Systemen zur Echtzeitlokalisierung sehr hoch. Das macht die Systeme nicht nur aufwändig und kostenintensiv, sondern auch ungeeignet für den befristeten und flexiblen Einsatz. Folglich ist der Nutzen dieser Systeme für KMU in Bezug auf den Funktionsumfang überschaubar und wird dem Aufwand zur Installation und Investition nicht gerecht.

Es lässt sich festhalten, dass KMU aus Effizienzgründen derzeit zur Prozessüberwachung und Beantwortung produktionslogistischer Fragestellungen vorrangig auf manuelle Methoden der Momentaufnahmen bzw. Selbstaufschreibungen zurückgreifen können, die jedoch bei komplexen Systemen limitiert sind. Es gibt folglich aktuell keine Methoden, mit denen KMU flexibel und effizient Produktions- und Logistikprozesse analysieren und Wirkzusammenhänge erkennen können, um daraus Optimierungspotential abzuleiten. Daraus ergeben sich folgende Anforderungen an eine KMU-geeignete Analyse-Methodik: geringer Initialisierungs- und Installationsaufwand, geringer Ressourcenbedarf zur Systemanwendung, kein Eingriff in KMU-interne Systeme, intuitive Bedienbarkeit, für temporären Einsatz geeignet und somit wiederverwendbar.

Auf dieser Basis haben die Autoren die Entwicklung einer Analyse-Methodik fokussiert, die der Zielstellung unterliegt, eine KMU-gerechte Methodik zur effizienten, temporär durchführbaren Datenerhebung und -auswertung in flexiblen Produktions- und Logistiksystemen als Basis zur Prozessanalyse und -verbesserung zu ermöglichen. Die Gesamtmethodik fokussiert die retrospektive Lokalisierung, Visualisierung und Analyse von Materialflussobjekten sowie deren Bewegungsprofilen im produktionslogistischen Umfeld. Um im Vergleich zur manuellen Zeitaufnahme eine objektive, ressourcenaufwandsarme Analyse umsetzen zu können und hinreichend komplexe Analysen (wie es verfügbare automatisierte Methoden zur Datenerfassung ermöglichen) jedoch mit reduziertem Installations-, Betriebs- und Investitionsaufwand realisieren zu können, ist eine entsprechende technologische Grundlage notwendig. Diese umfasst sogenannte Beacons, welche als Signaller (BLE) Einsatz finden, und SMD, bspw. Smartphones, als Empfänger. Die Entfernungsbestimmung erfolgt über den Received Signal Strength Indicator (RSSI), welcher ein Maß für die Signalfeldstärke zwischen Sender und Empfänger ist und in Distanzwerte transferiert wird.

Der primäre Forschungsansatz besteht im Rahmen der Analyse-Methodik in einer automatischen Erkennung lo-

gistischer Prozesse ausschließlich auf Basis der aufgenommenen Signalstärke-/Entfernungsdaten mit Hilfe von überwachten Maschinellen Lernalgorithmen. Ergänzend dazu zielt die retrospektive Visualisierung von Bewegungsprofilen aus den auf Basis der Signalstärke-Distanz-Daten abgeleiteten Positionsprofilen der Sender- und Empfängergeräte auf die Generierung einer korrekten Datenbasis zur umfassenden Analyse logistischer Prozesse ab. Die dafür notwendige Datenqualität bedarf sowohl die spezifische Konfiguration der Sender- und Empfängertechnologie, die Auswahl geeigneter Verfahren sowie Filter zur Glättung auftretender Signalschwankungen der RSSI-Daten als auch die Einbindung von Verfahren zur Bestimmung von Korrekturfaktoren in Abhängigkeit möglicher Signalstörungen (Säulen, Paletten). Einen weiteren wesentlichen Einfluss auf die Ergebnisgüte der verwendeten Klassifizierungsverfahren, Korrekturmodelle sowie Verfahren zur Visualisierung von Positionsprofilen haben die Parametersettings, die den jeweiligen Algorithmen zugrunde liegen.

Die nachfolgenden Ausführungen geben einen Überblick über die Gesamtmethodik des Analyse-Tools und des aktuellen Entwicklungsschwerpunkts der Datenaufbereitung sowie der hinreichend genauen Prozesszuordnung auf Basis von Signalstärke-Distanz-Daten. Der Einfluss der jeweiligen Faktor- und Parametersettings wird in diesem Beitrag ebenfalls diskutiert.

2 STAND DER TECHNIK

Die Nutzung der BLE-Signale auf Basis des RSSI-Wertes begründet sich vorrangig in der Anforderung, dass die Methodik eine hinreichende Positionsgenauigkeit bei der Verfolgung von Materialflussobjekten in Produktion und Logistik realisieren muss. Dies impliziert zudem, dass eine Datenaufnahme, Objektverfolgung und ggf. Lokalisierung meist innerhalb von Räumen stattfindet. Objektverfolgung und Lokalisierung auf Basis des GPS-Signals ist sehr verbreitet, stößt jedoch innerhalb von Gebäuden aufgrund der hohen abschirmenden Wirkung von Wandmaterialien (Stahlbeton, etc.) an die Grenzen der Genauigkeit. Die kostenintensive RFID-Technologie kommt für eine umfassende Datenaufnahme mit den gegebenen Anforderungen nicht in Frage, da wie bereits einleitend erwähnt, der Installationsaufwand hoch ist und die temporäre Anwendung mit dieser Technologie nicht fokussiert wird. Die Objektverfolgung und Datenaufnahme mittels UWB-Radiosignalen ist eine weitere Option für die Nutzung innerhalb von Gebäuden. Die Positionsgenauigkeit ist hoch und befindet sich im cm-Bereich [Zwi14]. Die hohe Präzisionsanforderung ist für die vorgestellte Methodik nicht notwendig. Lokalisierungsverfahren, welche auf Basis von wireless LAN (WLAN) Funksignalen arbeiten, genügen den Anforderungen an die Positionsgenauigkeit ebenso wie die Beacons. Für einen temporären Einsatz bieten die Beacons aufgrund der autarken Stromversorgung und der einfachen Installations-

tion wesentliche Vorteile. Zudem hat sich die Verfügbarkeit der Beacon Technologie in den letzten Jahren positiv entwickelt, sodass diese je nach Anforderung mit unterschiedlichen Funktionalitäten sowie zu geringen Kosten auf dem Markt erhältlich sind.

Seit 2005 nimmt die Nutzung der BLE-Beacons stetig zu und hat sich auch in der Forschung etabliert. Die Technologie wurde anfangs vor allem im Marketing, CRM und von Museen oder Bibliotheken eingesetzt, um kunden- bzw. besucherrelevante Informationen auf deren mobile Endgeräte zu pushen (z.B. [Moo16], [Cey016]). Mittlerweile finden BLE-Beacons in einer Vielzahl an Branchen Anwendung. So beschreiben Bohonos et al. [BLM07] die Entwicklung eines universellen Echtzeit-Navigationsassistenten (URNA) für blinde Menschen. Anwendungsbeispiele finden sich bspw. auch als „Eventbeacons“ zur interaktiven Sitzplatzvergabe bei Großveranstaltungen [CCR18] oder bei der Überwachung von Weidevieh zur Bestandskontrolle (Verlust- bzw. Diebstahlskontrolle) [HH17]. Im medizinischen Sektor ist vor allem der Einsatz von BLE-Beacons bei der Lokalisierung relevant, z.B. von Demenzpatienten [Hee15] oder zum schnellen Auffinden von medizinischen Materialien bzw. Geräten in Krankenhäusern [BSPD18].

Die aktuelle Forschungsliteratur fokussiert fast ausschließlich den industriellen Einsatz der BLE-Beacons zur Indoor-Lokalisierung bzw. zur Gewinnung ergänzender Daten und Information bei einer Anwendung in Kombination mit anderen Lokalisierungsverfahren bzw. durch Kopplung mit Sensor- oder anderen Signalen (WLAN, RFID, Sensoren, etc). So untersuchen Kriz et al. [KMK16] die Möglichkeiten zur Verbesserung der Lokalisierungsgenauigkeit unter der Anwendung von BLE-Beacons in Kombination mit WLAN Funksignalen innerhalb von Gebäuden. Von infsoft ist ein Tool zum Behältermanagement und Auftragsverfolgung in der Produktion entwickelt worden. Hierbei werden Behälter mit Beacons versehen, welche über integrierte Displays eine Zustandskontrolle sowie über festinstallierte Empfangsmodule eine Lokalisierung in Echtzeit ermöglichen [inf18]. Grogger et al. [GENS18] zeigen in ihrem Paper ein neuartiges Konzept für die Auftragsverfolgung basierend auf BLE-Beacons. Dieses findet Anwendung im Rahmen der Vorstellung eines szenario-basierten Produktionsdatenanalyse-Tools für die Produktion von Einzellosen bzw. Losen mit geringer Stückzahl. Die Beacons finden vorrangig Einsatz zur Übermittlung von Positions- und Sensordaten. Eine konkrete Analyse und Auswertung auf Basis der generierten RSSI-Daten findet nicht statt [GENS18]. Lindner et al. [LKGS17] greifen den Gedanken von Industrie 4.0 auf und untersuchen, inwieweit der Einsatz von Smart Devices (Smart Watches, Smartphones, etc.) in der Fertigung die Erweiterung von Schnittstellen zu Mensch und Maschinen und somit den schnellen und effizienteren Datenaustausch fördern kann. Die BLE-Beacons werden auch hier zur Indoor-Lokalisierung

rung genutzt und auf Basis der Signalfeldstärke die Position der mobilen Endgeräte in den Fertigungsbereichen bestimmt. Jedoch findet auch hier keine Nutzung der Datenbasis zur retrospektiven Datenanalyse und Verfolgung von Materialflussobjekten statt.

Die genannten Forschungsbeiträge bestätigen den oben genannten Anwendungsschwerpunkt der Indoor-Lokalisierung für BLE-Beacon. Die Verwendung der generierten RSSI-Werte und darauf basierende Positionsdaten zur gezielten Analyse und Auswertung der Produktions- sowie Materialflussprozesse wird kaum fokussiert. Wie bereits erwähnt, erfolgt für die Indoor-Lokalisierung und Analyse meist eine Kopplung verschiedener Datensets mit unterschiedlichen Ursprung (Sensordaten, Funkdaten (WLAN, RSSI, etc.)) zur Erhöhung der Datengüte und -genauigkeit. Dies begründet sich v.a. in der vorhandenen Instabilität der RSSI-Signale, welche einer hohen Streuung unterliegen [FZGX10]. Die Signalrohdaten müssen zur Erhöhung der Genauigkeit und der Lesbarkeit mit Hilfe von Methoden zur Signalglättung und Interpolation optimiert werden. Autoren, wie bspw. Jayakody et al. [JCLV16], Fang et al. [FZGX10], Zhao et al. [ZOSP17], Satan & Toth [ST18], beschäftigen sich bereits seit längerem mit der Kombination geeigneter Methoden und Ansätze. Bisher gibt es jedoch keine standardmäßige Vorgehensweise für die Signaloptimierung. Zudem fokussieren alle vorgestellten Ansätze den langfristigen Einsatz sowie die Generierung von Echtzeitdaten zur Positionsbestimmung. Es existiert bislang kein System, welches zur gezielten temporären Analyse von logistischen Prozessen ausschließlich BLE-Sender und SMD einsetzt sowie eine retrospektive Auswertung dieser Prozesse lediglich auf Basis generierter RSSI-Signaldaten durchführt.

Im Rahmen der Entwicklung der Analysemethodik liegt somit ein wesentlicher Fokus auf der Optimierung der unscharfen Signaldaten (RSSI). Ohne eine korrekte Datenbasis ist die fundierte Aussagefähigkeit der Analyse- und Auswertungsergebnisse nicht gegeben. Ergänzend zu den bekannten Signalglättungs- und Interpolationsmethoden (Rolling Mean, Auto Regressive Moving Average, polynomiale Regression, etc.) werden weitere Datenfilter, in Kombination mit Regelsets und Algorithmen aus dem Bereich des Maschinellen Lernens auf Eignung sowie deren Potentiale auf die Verbesserung der Datengüte untersucht.

Algorithmen aus dem Bereich des Maschinellen Lernens bilden die Grundlage zur Erkennung von Mustern in großen Datensätzen. In der Forschungsliteratur ist dieses Thema unter dem Oberbegriff Knowledge Discovery in Databases (KDD) bzw. Data Mining vereint und vor allem für den industriellen Bereich haben sich mit dem gesteigerten Interesse an Digitalisierung und Industrie 4.0 die Forschungsleistungen deutlich gesteigert. Die Mustererkennung wird im Besonderen bei einer automatisierten Zuordnung von Datensätzen zu vorgegebenen Datenklassen bzw. -kategorien angewendet. Es wird grundlegend

nach unüberwachtem und überwachtem Lernen unterschieden [GSS14]. Die für dieses Forschungsvorhaben geeigneten Lernalgorithmen zur automatischen Zuordnung von Prozessklassen zu den Entfernungsdaten basieren auf einer umfassenden Recherche in der aktuellen Forschungsliteratur und dem in der ScikitLearn-Bibliothek zur Verfügung stehenden Schema [SL18]. Für kategorisierte Daten bieten sich vor allem die Verfahren des überwachten Maschinellen Lernens an. In der Literatur sind gängige Methoden im Bereich der Klassifikation zu finden [Fro18]. Für die Klassifizierung von Prozessdaten auf Basis von RSSI-Signalwerten finden sich bisher in der Literatur keine standardisierten Klassifizierungsalgorithmen. Ein ähnliches Anwendungsfeld ist die Klassifizierung von Bewegungsdaten (Motion Capture), welche bereits im industriellen Umfeld eingesetzt wird. Zur Mustererkennung von Bewegungsdaten kommen vorrangig folgende Algorithmen für eine Klassifizierung zur Anwendung: Support Vector Machine (SVM) ([FH16], [AGOP12]), Künstliche Neuronale Netze (NN) ([PEKM06], [DCK12], etc.), Random Forrest ([PGGC17], [FH16], [EKGL14]) sowie AdaBoost [WDT15]. Ausgehend von diesen Erkenntnissen werden für die Analyse-Methodik die vorgestellten Klassifizierungsalgorithmen als Basis herangezogen und auf Eignung geprüft.

3 ANALYSEMETHODIK UND SOFTWAREARCHITEKTUR

3.1 TECHNOLOGIE

Wie bereits erwähnt, bilden Beacons als Bluetooth (BLE)-Sender und handelsübliche Smart Mobile Devices, wie Smartphones, die technologische Grundlage des Systems. Die Materialflussobjekte (Paletten, Gabelstapler, etc.) sollen mit den Empfangsgeräten ausgestattet und über die verteilten Beacons relative Bewegungsprofile aus Entfernungsdaten erstellt werden. Die Konstellation der Sender und Empfänger zueinander ist dabei abhängig von Untersuchungsszenario und den Gegebenheiten. Die Entfernungsbestimmung und somit die Aufnahme der Bewegungsprofile erfolgt über den iBeacon Standard mittels RSSI. Die Vorteile der Beacon-Technologie liegen in einer hohen Reichweite (zwischen 1 m – 70 m), keinen inhärenten Sicherheitsrisiken, einer freien Entwicklungsumgebung (z.B. AltBeacon-Bibliothek), und der Möglichkeit zur Individualisierung (over the air Konfiguration) sowie einem niedrigen Aufwand für Anschaffung und Initialisierung. Für das entwickelte Analysesystem wurden Beacons diverser Hersteller auf Eignung getestet. Für die optimale Systemkonfiguration ist v.a. eine Variation des Advertising Intervalls, d.h. der Sendefrequenz, und des tx-Power Wertes (Signalreichweite) relevant. Smartphones als standardisierte Geräte sind in umfangreichen Varianten kostengünstig verfügbar. SMD zur individuellen Konfiguration, wie der Raspberry Pi, bieten zahlreiche Möglichkeiten zur Systemindividualisierung und anforderungsgerechten Hard-

wareanpassung. Im Entwicklungsprozess kamen Smartphones mit Android-Betriebssystem und Bluetooth 4.1 Schnittstelle zum Einsatz.

3.2 LÖSUNGSANSATZ

Die Anwendung des Analysesystems erfolgt in vier grundlegenden Schritten (siehe Abbildung 1). Allen voran muss je Untersuchungsszenario bzw. Anwendungsfall ein Untersuchungsziel definiert werden, welches sich zumeist durch Kennzahlen ausdrücken lässt. Hier können als Beispiel die Auslastung von Flurförderzeugen oder die Durchlaufzeit von Behältern genannt werden. Im Rahmen der Zielerarbeitung wird der notwendige Datenbedarf bzw. die notwendige Datenbasis aufgezeigt.

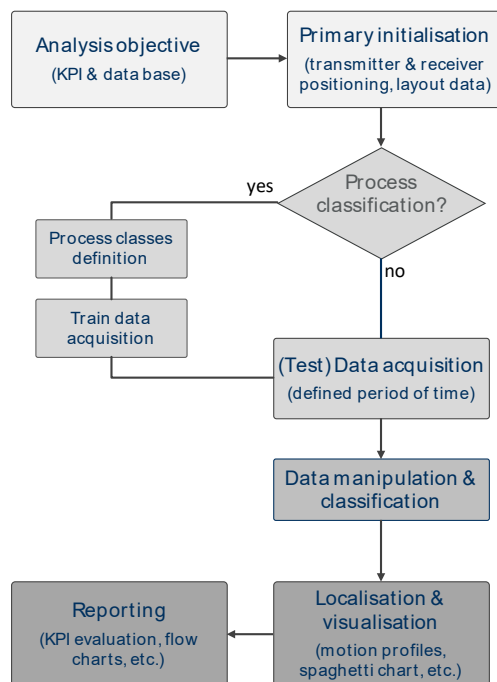


Abbildung 1. Anwendung Analysesystem

Nach einer Initialisierungsphase, in der je nach Untersuchungsszenarien Sender und Empfänger im entsprechenden Produktions- bzw. Logistikumfeld positioniert und im Layout zugeordnet worden, erfolgt die Datenaufnahme. Wird während der Analysephase eine Prozessklassifizierung benötigt, erfolgt im ersten Schritt die Generierung von Trainingsdatensätzen zum Anlernen der Klassifizierungsalgorithmen. Hierbei werden während der Datenaufnahme den im System ablaufenden Prozessen definierte Prozessklassen zugeordnet. Nachfolgend erfolgt die eigentliche Datengenerierung über einen festgelegten Zeitraum. Die generierten Daten werden anschließend mittels Verfahren der Signalaufbereitung optimiert, womit die Grundlage für eine notwendige Qualität und Güte der Daten für die weitere Auswertung und Analyse gelegt wird. Neben der Auswertung hinsichtlich spezifischer Untersuchungsziele, die abhängig vom jeweiligen Szenario (Auftragsdurchlaufzeit,

Leerfahrten, Transportauslastung, etc.) sind, werden durchgeführte logistische Prozesse automatisiert den Entfernungsdaten zugeordnet und somit wird eine entsprechend detaillierte Datengrundlage für die prozessbezogene Analyse zur Verfügung gestellt. Die retrospektive Lokalisierung bzw. Visualisierung von Bewegungsprofilen zählt ebenfalls zum Umfang des entwickelten Analyse-Tools und dient der visuellen Auswertung in Form von Spaghetti- oder Sankey-Diagrammen.

3.3 MODULARE SYSTEMARCHITEKTUR

Die Gesamtmethodik des Analysetools ermöglicht durch eine modulare Software-Architektur (siehe Abbildung 2) bestehend aus Modulen zur Datenaufnahme (App-basiert), zur Datenaufbereitung sowie zur Datenspeicherung (Datenbank-basiert) und einer Analyse- bzw. Berichtseinheit gezielte Anpassungen an variiere Untersuchungsszenarien (Abbildung 1).




Abbildung 2. Modulare Software-Architektur

Der Demonstrator zur Primärinitialisierung und Datenaufnahme steht in Form einer Java-basierten Applikation zur Verfügung (siehe Abbildung 3), welche die Datenaufnahme von Trainings- und Testdaten sowie die Anpassung relevanter Parameter ermöglicht. Die Hinterlegung von individuellen Layoutdaten ermöglicht die genaue koordinatenbasierte Zuordnung der verwendeten Beacons zu den Primärpositionen. Die Zuordnung erfolgt intuitiv über die GUI.

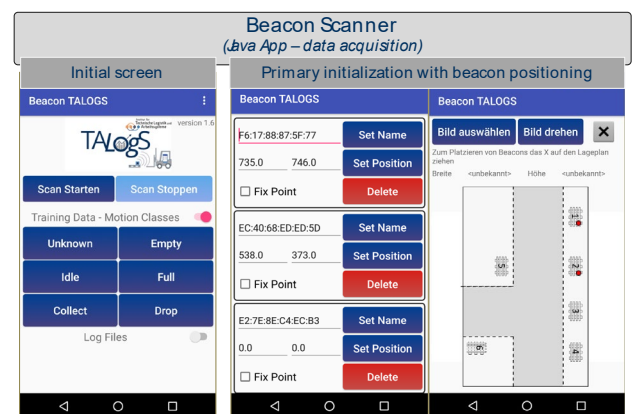


Abbildung 3. Beacon Scanner (Android App)

Das hinterlegte Koordinatensystem wird auf Basis von Bildpunkt der Layoutdaten bestimmt und bildet die Grund-

lage für eine nachfolgende Visualisierung der Positionsdaten in Form eines Bewegungsprofils. Die Entwicklung einer eigenen Android-App begründete sich in der fehlenden Eignung freiverfügbarer Beacon- bzw. BLE-Scannern. Vor allem die Konfigurationsmöglichkeiten für eine zielgerichtete Datenaufnahme, die Implementierung und Parametervariation notwendiger Verfahren zur Signalglättung und ein geeignetes Ausgabeformat der Signalrohdaten waren Anforderungen, die die meisten Open Source Anwendungen nicht ermöglichten (Beacon Scanner, iBeacon & Edystone Scanner, etc.).

Die Datenaufbereitung erfolgt in einem weiteren, eigenständigen Software-Modul, welches Python-basiert und in einer Datenbank eingebunden arbeitet. Die Funktionalität des Moduls beinhaltet die Überführung der aufgenommenen Rohdatenformate (timestamp, Motion, Distanz [num], etc.) in lesbare Datenformate (Datetime, Prozessklasse, Distanz [m], etc.). Tabelle 1 und Tabelle 2 zeigen beispielhaft die Konvertierung eines Datensatzes vom aufgenommenen Rohdatenformat in die favorisierten Datenformate.

Tabelle 1. Format Rohdaten

Timestamp	Motion	MAC_s	MAC_RSSI
01.06.2018 14:42:54	Unknown	0.91841...	-60

Tabelle 2. Datenformat konvertierte Daten

Datetime	Prozessklasse	MAC_s	...
01.06.2018 14:42:54	Unknown	0,92	
...	MAC_RSSI	MAC_v	MAC_a
	-60	0,17	0,57

Neben der Datenkonvertierung in geeignete Datenformate umfasst die Funktionalität des Moduls die Datenaufbereitung und -optimierung, welche für die nachfolgende Datenanalyse die Generierung einer robusten Datenbasis ermöglicht.

Die Aufbereitung der RSSI-Werte zur Analyse und Auswertung teilt sich im Rahmen der Software-Architektur in zwei Bereiche und ist ebenfalls Datenbank-basiert. Für das erste Software-Modul werden zur Erreichung einer automatisierten Zuordnung von definierten Prozessklassen zu den Entfernungsdaten mit dem Ziel einer hohen Übereinstimmung zur tatsächlich erfolgten Bewegung geeignete Verfahren des Maschinellen Lernens insbesondere Klassifizierungsalgorithmen aufgegriffen, kombiniert und implementiert. Die Implementierung in Python erfolgt mit Hilfe der Scikit-Bibliothek. Die Übertragbarkeit der eingangs aufgezeigten Klassifizierungsalgorithmen auf RSSI-Daten

bzw. Prozessdaten aus dem produktionslogistischen Anwendungsbereich wurden vor der Implementierung in Studien getestet. Vor allem die Klassifizierungsalgorithmen Neuronale Netze, Support Vector Machine (SVM) und Random Forrest erzielten je nach Komplexität der Versuche im Durchschnitt eine Klassifizierungsgenauigkeit von ca. 80 %. Zum Anlernen der jeweiligen Klassifizierungsalgorithmen mit spezifischen Trainingsdaten stehen in der entwickelten App zur Datenaufnahme bereits standardisierte Prozessklassen (Motion Classes) bereit. Ergänzend dazu können individuelle Prozessklassen je nach Untersuchungsszenario hinterlegt werden. Diese werden bei der Datenaufbereitung mit übertragen.

Der zweite Bereich der Analyse und Auswertung dient der Visualisierung der relativen Prozessdaten für die Realisierung eines retrospektiven Tracings. Schwerpunkt dieses Software-Moduls ist die Umsetzung einer Methode zur Überführung der Prozessdaten mit hinterlegtem Positionsprofil in ein Bewegungsprofil (siehe Abbildung 4).

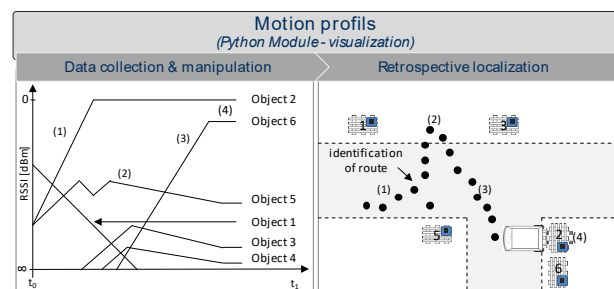


Abbildung 4. Software-Modul zur Visualisierung der Bewegungsprofile

Aktuell erfolgt die Umsetzung auf Basis der relativen und klassifizierten Entfernungsdaten sowie eingehender Layoutdaten der entsprechenden Untersuchungsszenarien unter Kombination von Methoden zur Positionsbestimmung (z.B. Trilateration, Multilateration, etc.). Herausforderungen bestehen v.a. in der Verbesserung der Positionsgenauigkeit / Lokalisierung. Es wird eine Kombination aus verschiedenen Verfahren angestrebt. So werden bspw. Geofencing, Methode des kleinsten Quadrats sowie die Implementierung bestimmter Regelsätze für die Verbesserung der Positionsgenauigkeit in Betracht gezogen. Die Regelsätze greifen bspw. auf Layoutdaten zurück, die Vorgaben zu Sperrbereichen enthalten, und prüfen die ermittelten Positionen auf deren Gültigkeit. In der Forschungsliteratur gibt es eine Vielzahl an Veröffentlichungen in diesem Themenbereich (z.B. [ZYLQ17], [GFFM18], [RLJA15]).

4 HERAUSFORDERUNG DATENQUALITÄT

4.1 SIGNALDATEN & DEREN EINFLUSSGRÖßEN

Im Rahmen der vorgestellten Analysemethodik stellen die einzelnen Module der Software-Architektur unabhän-

gige Komponenten dar, die eine Datenverarbeitung durchführen. Somit haben diese Module je einen Dateninput und einen Datenoutput. Die Güte und Qualität der Inputdaten beeinflusst zwangsläufig die Güte der Ergebnisdaten. Hinzukommen kommen evtl. vorhandene Stell- bzw. Einflussgrößen bei der Datenverarbeitung. Entspricht die Güte der Eingangsdaten nicht den definierten Anforderungen, können keine fundierten Ergebnisdaten erwartet werden. Somit ist eine Optimierung der unscharfen Signaldaten zu Beginn und im Laufe des Analyseprozesses notwendig.

Die gegebene Unschärfe der Signalrohdaten (RSSI-Werte) begründen sich bspw. in der vorhandenen Instabilität des Übertragungssignals, den technologischen Schnittstellen sowie in vorhandenen Störgrößen. Als Beispiel zeigt die folgende Abbildung 5 ein über ein Zeitintervall aufgenommenes RSSI-Signal mit einem konstanten Abstand zwischen stationären Sender (Beacon) und Empfänger von 3 m. Die Aufnahme erfolgte in einer Produktionshalle. Die deutlich erkennbaren Signalschwankungen können ohne Aufbereitung bzw. Korrektur bei Weiterverarbeitung, Bestimmung der Distanzwerte sowie bei Kombination mit anderen Datensätzen zu einer Verfälschung der Analyseergebnisse führen.




Abbildung 5. Unschärfe Rohsignal (RSSI)

Der primäre Forschungsfokus liegt somit neben der Definition der Anforderung an Datengüte und -qualität in der Auswahl, Kombination, Parametrierung und Implementierung geeigneter Verfahren zur Signaldatenaufbereitung. Im Besonderen sind die Parameterausprägungen der jeweiligen Verfahren sowie deren Einfluss auf die Datengüte sowohl bei der Datenaufnahme, -verarbeitung als auch in den abschließenden Analyse- und Auswertungsmodulen Untersuchungsschwerpunkt. Den verwendeten Klassifizierungsalgorithmen liegen ebenfalls Parametersets zugrunde. Der Einfluss variierender Parameterausprägungen auf die Klassifizierungsgenauigkeit und damit auf die Ergebnisgüte ist ein weiteres Untersuchungsfeld.

Ergänzend dazu darf der Einfluss von externen Störgrößen, wie Signaldämpfungseffekten, sowie technologieabhängige Einflussfaktoren nicht außer Acht gelassen werden. Hier ist neben der Konfiguration der Sender- und Empfängertechnologie (Advertising Intervall, Scanrate, Reichweite, etc) auch deren Schnittstellentechnologie kritisch zu prüfen und entsprechende Korrekturmethode zu hinterlegen. Die Häufigkeit vorhandener Signalstörquellen ist vor allem im industriellen Umfeld durch Maschinen,

Baumaterialien und anderen Signalarten besonders hoch. Hier ist ebenfalls detailliert der tatsächliche Einfluss auf die Signaldaten zu prüfen sowie die geeigneten Korrekturmodelle abzuleiten und zu implementieren. Zusammenfassend ergibt sich somit ein komplexes Wirkmodell aus den externen Störgrößen, technologisch bedingten Einflussfaktoren, Algorithmen zur Datenverbesserung sowie deren Parameterkombinationen, welches sukzessive zu untersuchen und hinsichtlich der Einflussnahme der einzelnen Faktoren auf die Datengüte zu bewerten ist. Die langfristige Zielstellung besteht darin, ein umfassendes Korrekturmodell zu erarbeiten, welches eine Kombination von standardisierten sowie szenariobasierten Parametersettings und Verfahren zur Signal- und Datenaufbereitung ermöglicht.

4.2 SIGNALAUFBEREITUNG & DISTANZKALKULATION

Grundlegend für die Gewährleistung einer hohen Genauigkeit der aufgenommenen RSSI-Signalwerte ist die Sender- und Empfängertechnologie sowie die Umgebung. Neben der angesprochenen szenariobasierten Konfiguration sowie Festlegung der Parametersets der Beacons und SMD, müssen für letztere je nach eingesetztem Gerätemodell individuelle Distanzkorrekturkoeffizienten ermittelt werden.

Bei experimentellen Datenaufnahmen im Rahmen von Versuchsszenarien konnte diese Signalschwankungen bestätigt werden (siehe obenstehende Abbildungen). Es wurden bei identischem Versuchsszenario und identischer Gerätekonfiguration je verwendetem Empfängergerät zu einen Signalwerte mit unterschiedlichen Streuungsbreiten aufgenommen (Abbildung 6). Zum anderen kam es bei der Überführung der Signaldaten in Entfernungsdaten zu einer Abweichung zur realen Distanz zwischen Sender und Empfänger (Abbildung 7).




Abbildung 6. Einfluss Empfängertechnologie




Abbildung 7. Einfluss Empfängertechnologie auf die Distanzkalkulation

Dies begründet sich neben dem Signalrauschen in den in der Aufnahmeumgebung befindlichen Hindernissen und Störgrößen (Säulen, Maschinen, Wände, etc.) ebenso wie in der Schnittstellentechnologie der SMD.

Somit wurden im ersten Schritt die für eine optimale Konfiguration der Sender und Empfänger sowie für die Entwicklung der Analyse-Methodik relevanten Parameter (siehe Tabelle 3) definiert:

Tabelle 3. Parameter Datenaufnahme

BLE-Sender (Beacons)	Empfänger (SMD)
Advertising Intervall	Scan Periode
tx-Power (Reichweite)	RSSI Filter [ALB19]
Major / Minor	→ Running Average (Fenstergröße) → Auto Regressive Moving Average (ARMA Faktor)

Die Parameter Major und Minor ergeben sich aus dem genutzten Bluetooth iBeacon Standard. Beide Parameter werden neben der MAC-Adresse zur eindeutigen Identifizierung der Beacons herangezogen. Die Festlegung der Parameter der Empfangsgeräte sind in der Applikation zur Datenaufnahme hinterlegt.

Als grundlegende Parametereinstellung hat sich in den Vorversuchen die Angleichung von Advertising Intervall und Scan Periode bewährt. Der Bereich liegt je nach Versuchsszenario zwischen 100 ms und 1 sek. Der tx-Power Wert ist bei allen verwendeten Beacons auf den Nullwert eingestellt, welcher eine hohe Signalreichweite zulässt sowie einen identischen RSSI-Wert@1m von -59 dBm vorgibt. Vorrangig findet der Running Average für die Signalaufnahme Anwendung und wird mit einer Fenstergröße gleich der Scanperiode gewählt, somit wird gewährleistet, dass alle empfangenen Signalpakete während einer Scanperiode eingebunden werden und die Glättung der Signaldaten zu keiner Verfälschung der Datenbasis führt.

Im aktuellen Entwicklungsstand steht bereits ein Methodenpaket aus Interpolationsfiltern und Signalglättungsmethoden zur Verfügung, welches im Rahmen des Software-Moduls zur Datenaufbereitung zur Anwendung kommt. Im Konkreten sind die Methoden des Gleitenden Durchschnitts (Rolling Mean – RM) für verschiedene Parameter, Interpolationsfilter (polynomial, spline, cubic und linear) sowie Verfahren zur Datenbereinigung. Die Datenbereinigung zielt hier vor allem auf das Auffinden und Beseitigen von Ausreißern ab. Zum einen werden positive RSSI bzw. negative Distanzwerte entfernt. Zum anderen werden Minimal- und Maximalwerte auf Basis von Median und einem Vielfachen der Standardabweichung bestimmt ($Grenzwert = \bar{x} \mp x * \sigma$). Rohdaten, die ober- bzw. unterhalb dieser Grenzwerte liegen, werden ebenfalls entfernt. Aktuelle Bemühungen sehen die Optimierung der Parametereinstellungen vor. Das bedeutet, es wird eine Parametervariation durchgeführt. Dabei werden die einfließenden Signalrohdaten, welche von mehreren Empfängergeräten in einem identischen Versuchsszenario aufgenommen wurden, mittels variierender Parametersettings (siehe

Tabelle 4) der einzelnen Methoden aufbereitet und das Ergebnis dahingehend geprüft, wie sich die berechneten Distanzwerte im Einzelnen und im Verlauf der Realität annähern.

Tabelle 4. Variation Parametereinstellung

Parameter	Hinterlegung	Variation
Rolling Mean	Empfänger	50, 100, 1000 [ms]
Scan Periode	Empfänger	10, 100, 500, 1000 [ms]
ARMA	Empfänger	0.05, 0.25, 0.5 [%]
Rolling Mean	Software-Modul	1, 3 [sek]
Interpolation	Software-Modul	cubic, linear, polynomial, spline [Order 3, 5]
Ausreißer	Software-Modul	Faktor x von σ
Distanzkorrekturfaktor	Software-Modul	definiert

Durch die Vielzahl möglicher Parameterkombinationen unterliegt die Analyse und die Ableitung optimaler Parametersets einer hohen Komplexität. Des Weiteren haben die bereits durchgeführten Auswertungen gezeigt, dass es nicht zielführend ist, ein Default-Parameterset für alle aufzubereitenden Rohdaten anzunehmen.

Zur individuellen Distanzkorrektur wurde im Rahmen der Untersuchungen für jedes während der Entwicklung verwendete SMD eine Annäherungsbestimmung (Messung Entfernung ISTphysisch zu ISTSignal) durch Transformation der RSSI-Werte in Distanzwerte vorgenommen. Die Annäherungsbestimmung wird nach dem Modell der Android Altbeacon Library [ALB19] durchgeführt. Das Android Beacon Library Modell basiert auf einem Verlustfaktor, welcher in nicht logarithmierter Form vorliegt. Der Ansatz dieses Modells liegt darin, dass die RSSI-Werte und Leistungsverluste sender- und empfangerspezifisch sind. Die Bestimmung der Koeffizienten erfolgte in einer idealisierten Umgebung, um zum einen andere Einflussgröße, wie andere Signalarten, dämpfende Materialien, o.ä., zu minimieren und somit ein möglichst genaues und gerätespezifisches Distanzkorrekturmodell zu erhalten. Die Annäherungsbestimmung erfolgte auf einer ebenen Freifläche ohne umschließende Bebauung sowie abseits von städtischen und industriellen Einflüssen. Es wurden je SMD je Distanz (0,25 m – 40,00 m) je drei Messungen aufgenommen. In Abbildung 8 ist beispielhaft ein Kurvenverlauf für die Annäherungsbestimmung eines SMD dargestellt. Es ist deutlich erkennbar, dass mit zunehmender Distanz zwischen SMD und Beacon die RSSI-Werte stärker schwanken.

Die abgeleiteten Korrekturkoeffizienten finden Anwendung im Rahmen der Datenaufbereitung und sind im entsprechenden Softwaremodul hinterlegt und können je

verwendeten SMD ausgewählt werden. Die in Abbildung 7 dargestellte fehlerhafte Distanzkalkulation konnte für die bisherigen Versuchsaufbauten der Realität sowie Empfangsgerät-spezifisch angenähert werden.




Abbildung 8. Annäherungsbestimmung SMD

Der Einfluss von Störgrößen, v.a. im produktiven Umfeld, ist wie bereits erwähnt durch vorhandene Maschinen, verwendete Baustoffen (Stahlbeton, Bleche, etc.), anderen Personen oder der Ausbreitung anderer Signale besonders hoch ([Sch19], [BHAD13], etc.). Vorhandene Störfaktoren bzw. Dämpfungseffekte, wie bspw. Reflexion, Streuung oder Absorption, lassen sich in zwei Gruppen aufteilen – fast fading und slow fading. Slow fading wird auch als Signalschwund aufgrund der Materialdurchdringung bezeichnet, wobei fast fading sich durch Interferenzen begründet, die zu einer Verstärkung oder Abschwächung der Wellen der Signale führen ([Tab10]; [WHC07]). In Abbildung 9 ist bspw. der Dämpfungseffekt slow fading deutlich zu erkennen. Die Werte der empfangenen RSSI-Signale werden deutlich abgeschwächt, was bei der Entfernungsbestimmung eine größere Distanz des Beacons (im Beispiel eine Verdopplung der Distanz) zum Empfängergerät suggeriert als es der Realität entspricht. Der Grund für die auftretende Dämpfung war in diesem Fall ein Lagermodell aus Holz und Metall, hinter welchem der Beacon platziert war.




Abbildung 9. Einfluss Signaldämpfung

Zusätzlich haben bereits umfangreiche Studien zu Dämpfungsfaktoren im realen Produktionsumfeld detaillierte Informationen über die Relevanz der Dämpfungseffekte für die Distanzbestimmung ergeben. So konnte nachgewiesen werden, dass sowohl der Mensch als auch metallische Gegenstände, wie Maschinen, oder metallverstärkte Materialien, wie stahlarmierter Porenbeton, die größten Dämpfungseffekte bewirken. Als Konsequenz für den Einsatz der Beacon-Technologie erfolgt die Positionierung der BLE-Sender in mit „Sichtkontakt“, das bedeutet, dass entlang der Signalausbreitung zwischen Sender und Empfänger keine bzw. kaum dämpfungsverursachende

Störgrößen vorhanden sein sollten. Alternativ müssen vorhandene Störgrößen und die daraus folgenden Dämpfungseffekte bei der Primärinitialisierung dem System kenntlich gemacht und die verfälschten Signaldaten durch Korrekturmethode oder der Einbindung von Meta-Informationen (z.B. Layoutdaten) in ergänzenden Regelsets retrospektiv bei der Datenaufbereitung optimiert werden. Als Korrekturmethode kommen im aktuellen Entwicklungsstand pauschalisierte szenariospezifische Dämpfungskonstanten in Verbindung mit dem Log-Distance Path Loss Model [Kün08] zum Einsatz. Im Rahmen weiterer Fallstudien werden die Konstanten geprüft und sukzessive für verschiedene Szenarien detailliert.

5 PROZESSKLASSIFIZIERUNG

5.1 DEFINITION PROZESSKLASSEN

Die Mustererkennungsverfahren aus dem Bereich des überwachten Lernens benötigen zum Anlernen der jeweiligen Algorithmen eine umfangreiche Datenbasis aus Trainingsdaten. Für die Klassifizierungsalgorithmen bedeutet dies, es muss eine Datenbasis zur Verfügung stehen, die je nach Untersuchungsszenario individuell generiert wird und alle wesentlichen logistischen Prozessklassen (Motion Classes) abdeckt. Die Definition der Prozessklassen ist abhängig von der betrachteten logistischen Prozesskette und kann je nach Anforderung und möglicher Granularität in einzelne Bausteine (Klassen) zerlegt werden. Dieser Schritt ist die Ausgangsbasis für die Klassifizierung auf Basis von Entfernungsdaten. Die Klassifizierungsalgorithmen nutzen in der aktuellen Anwendung zur Mustererkennung einen je Zeitpunkt verfügbaren Datensatz. Das heißt, je komplexer die Prozesse und Gegebenheiten in einem Untersuchungsszenario sind, umso umfassender und robuster muss die Datenbasis zum Anlernen der Lernalgorithmen sein, damit nachfolgend eine entsprechend hohe Klassifizierungsgenauigkeit erreicht werden kann.

Die Definition der notwendigen Prozessklassen für eine hinreichend genaue Klassifizierung wurde im ersten Schritt für ein klassisches Gabelstaplerrundfahrtproblem realisiert. Die Zerlegung der Prozesskette einer Gabelstaplerfahrt mit Materialumschlag wurde auf fünf Klassen reduziert: Aufsammeln, Ablegen, Fahrt ohne Ladung, Fahrt mit Ladung, Stillstand. Die einzelnen Klassen umfassen weitere detaillierte Unterprozesse. Hier kann z.B. genannt werden, dass ein Gabelstapler beim Aufnehmen von Ladung eine Positionierung der Gabel vor der Palette vollzieht. Die fünf Prozessklassen wurden bereits in Feldstudien im realen produktionslogistischen Umfeld getestet. Hierbei konnte festgestellt werden, dass die Übergänge zwischen den Prozessen, bspw. bei „Aufsammeln“ zu „Fahrt mit Ladung“, schwer abzugrenzen sind. Vor allem bei der Aufnahme von Trainingsdaten für das Anlernen der Mustererkennungsalgorithmen durch Personen, die mit der App nicht vertraut sind, wie bspw. einen Gabelstaplerfahrer, ist eine klare Abgrenzung der einzelnen Prozessklassen

zwingend erforderlich. Eine weitere Reduzierung der Prozessklassen auf lediglich drei Klassen (Fahrt mit Ladung, Leerfahrt und Stillstand) konnte die aufgezeigte Problematik nicht lösen. Weiterhin muss in Betracht gezogen werden, dass die Trainingsdaten nach aktueller Vorgehensweise händisch über die Eingabe der jeweiligen Prozessklasse per App erfolgt. Auch hierdurch wird zusätzlich eine Unschärfe in die Datenbasis eingebracht.

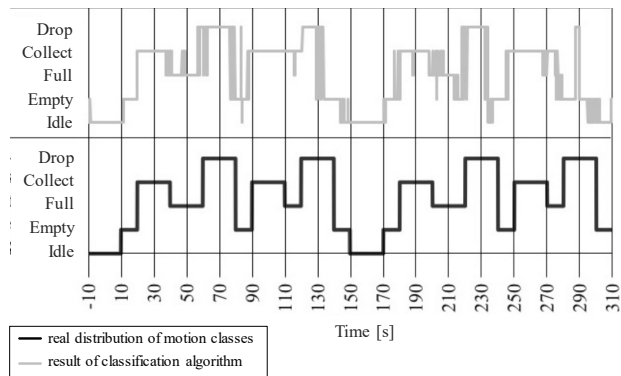


Abbildung 10. Vergleich Ist-Prozessklassen zu Klassifizierungsergebnis

In der Erprobungsstudie konnten die genannte Unschärfe im Bereich der Prozessübergänge auch anhand der Daten festgestellt werden. Die Klassifizierungsalgorithmen weisen demnach v.a. im Übergangsbereich zwischen den Prozessklassen Schwächen bei der korrekten Zuordnung auf (siehe Abbildung 10).

5.2 OPTIMIERUNG KLASSIFIZIERUNGSGENAUIGKEIT

Die fehlerhafte Zuordnung der Prozessklassen lässt sich zum einen mit den o.g. Fehlern bei der Aufnahme der Trainingsdaten erklären, zum anderen beziehen die Algorithmen nur einen Datensatz je Zeitstempel zur Klassenzuordnung ein. Vorgänger-Nachfolger-Beziehungen finden keine Berücksichtigung.

Daher zielt ein aktuell verfolgter Ansatz zur Erhöhung der Klassifizierungsgenauigkeit auf die Entwicklung und Implementierung von Regelsets ab, welche nach den eigentlichen Klassifizierungsalgorithmen das Klassifizierungsergebnis hinsichtlich logischer Klassenzuordnung, erreichter Vorhersagewahrscheinlichkeit sowie weiteren Prüfparametern untersuchen und ggf. anpassen. Als Ausgangsbasis wurde eine Reihenfolgematrix erstellt, welche Kombinationsmöglichkeiten von Prozessklassen definiert und somit die Logikbeziehungen zwischen den Klassen vorgibt (siehe Abbildung 11). Es hat sich in den Erprobungsstudien gezeigt, dass trotz Logikprüfung einige Prozessklassen fehlerhaft zugeordnet worden. Dies lässt sich mit vorhandenen Ausreißer-Datensätzen erklären. Zur Minimierung der Ausreißer werden vor der eigentlichen Logikprüfung die klassifizierten Datensätze bereinigt. Dazu dient zum einen die Bestimmung des Parameters „Fenster-

größe“, welcher eine bestimmte Anzahl aufeinanderfolgender gleicher Prozessklassen voraussetzt. Die tatsächliche Klassenlänge wird mit der „Fenstergröße“ abgeglichen und bei Bedarf die Prozessklasse für die entsprechende Länge fortgeschrieben.

	Stillstand	Aufsammeln	Fahrt mit Ladung	Ablegen	Fahrt ohne Ladung
Stillstand		x	x	x	x
Aufsammeln	x		x	x	-
Fahrt mit Ladung	x	-		x	-
Ablegen	x	x	-		x
Fahrt ohne Ladung	x	x	-	-	

Abbildung 11. Reihenfolgebeziehung Prozessklassen

Zum anderen wird jeder vorab definierten Prozessklasse eine Vorhersagegenauigkeit zugeordnet und mit dem definierten Parameter der „Vertrauenswahrscheinlichkeit“ abgeglichen. Ist die Vorhersagegenauigkeit einer Klasse größer als die Vertrauenswahrscheinlichkeit gilt die zugeordnete Prozessklasse als korrekt und wird übernommen. Die optimale Fenstergröße sowie Vertrauenswahrscheinlichkeit wurden über eine Parametervariation bestimmt. Des Weiteren wurde ebenfalls geprüft, welchen Einfluss die Größe der Datenbasis auf die Genauigkeit der Klassifizierungsalgorithmen sowie die Leistungsfähigkeit der Regelsets hat. Es hat sich gezeigt, dass die Datenbasis mindestens 12.000 Datensätze umfassen sollte, um aussagekräftige Ergebnisse zu generieren. Die notwendige Größe der Datensätze steigt mit der Komplexität des Untersuchungsszenarios an. Mit dem entwickelten Algorithmus konnten bislang sehr gute Ergebnisse erzielt werden. Im Durchschnitt konnten die Klassifizierungsergebnisse hinsichtlich des Accuracy-Wertes [Bro14] um 30 % verbessert werden. Die einzelnen Regelsets wurden sukzessive erarbeitet, an mehreren Versuchsdatensätzen geprüft sowie in das entsprechende Software-Modul implementiert.

Neben den Inputdaten haben vor allem die Parametersettings der verwendeten Mustererkennungsverfahren einen wesentlichen Einfluss auf die Klassifizierungsgüte. Jeder Klassifizierungsalgorithmus gibt ein eigenes Parameterset vor, welches je nach Wert der einzelnen Parameter die Leistungsfähigkeit der Klassifikatoren stark beeinflusst. Detaillierte Analysen auf Basis durchgeführter experimenteller Studien haben bspw. für die SVM ohne Einsatz von Kernels einen deutlichen Leistungsabfall gezeigt (siehe Tabelle 5), ebenso beeinflussen einige Parameterkombinationen mit Kernel (Lineare Kernel-Funktion mit logistic sigmoid function und stochastic gradient descent (SGD) Solver) (siehe Tabelle 6) die Genauigkeitsrate des Klassifizierers negativ (Reduzierung Genauigkeitsrate (CA) im Durchschnitt um 20 %).

Jedoch muss festgehalten werden, dass eine deutliche Abhängigkeit zu der Komplexität des Untersuchungsszenarios besteht. In den durchgeführten Erprobungsstudien wurden in fünf verschiedenen Versuchsszenarien, die sehr einfache geradlinige Annäherungsbewegung bis hin zu komplexe Aufnahme, Transport- und Ablageprozesse umfassen, Trainings- und Testdaten aufgenommen. Die Genauigkeitsrate der ausgewählten Klassifizierungsalgorithmen variiert stark zwischen den Szenarien. Es ist zudem kein eindeutiger Zusammenhang zwischen den Parameter-settings, der Ausprägung der Genauigkeitsrate und den Versuchsszenarien zu erkennen.

Tabelle 5. CA bei Anwendung SVM ohne Kernel-Funktion

Parameter-einstellung		Cost: 1; Regression loss ϵ : 0,1; Numerical tolerance: 0,01; Iteration limit: 200			
Klassifizierer		SVM			
		ohne Kernel-Funktion			
V1	CA	0,66	0,73	0,52	0,59
V2		0,44	0,34	0,35	0,41
V3		0,59	0,20	0,66	0,62
V4		0,59	0,22	0,55	0,49
V5		0,32	0,26	0,32	0,60

Tabelle 6. CA bei Kombination SVM mit Kernel-Funktion

Parameter-einstellung	Cost: 1; Regression loss ϵ : 0,1; Numerical tolerance: 0,01; Iteration limit: 200		
Klassifizierer	SVM		
Kernel	Linear		
Activation	Logistic		
Solver	L-BFGS-B	SGD	Adam
V1	0,90	0,70	0,92
V2	0,73	0,68	0,68
V3	0,86	0,76	0,87
V4	0,61	0,73	0,66
V5	0,70	0,65	0,66

Die bei den bisherigen Untersuchungen positiv hervorgetretenen Parameterkombinationen (z.B. SVM-Kernel-Adam (stochastic gradient-based optimizer) Solver oder NN-Adam/ NN-L-BFGS-B (an optimizer in the family of quasi-Newton methods)) (siehe Tabelle 7) werden für die weitere Anpassung und Optimierung der Prozessklassifizierung einbezogen.

Tabelle 7. CA bei Kombination NN mit Activation- und Solver-Funktion

Parameter-einstellung	Neurons per hidden layer: 200, Alpha: 0,0001, Max iterations: 300								
Activation	Logistic			tanh			ReLU		
Solver	L-BFGS-B	SGD	Adam	L-BFGS-B	SGD	Adam	L-BFGS-B	SGD	Adam
V1	0,92	0,70	0,92	0,89	0,92	0,93	0,89	0,92	0,92
V2	0,69	0,68	0,68	0,73	0,78	0,70	0,74	0,78	0,75
V3	0,86	0,76	0,87	0,85	0,86	0,86	0,84	0,87	0,87
V4	0,65	0,72	0,68	0,68	0,69	0,66	0,64	0,72	0,71
V5	0,72	0,64	0,66	0,67	0,67	0,72	0,60	0,66	0,66

Neben der o.g. nachgelagerten Verbesserung der Klassifizierungsgenauigkeit auf Basis von bereits klassifizierten Datensätzen steht aktuell die Optimierung der Parametersets der Klassifizierungsalgorithmen im Fokus. Die vorgelagerte Definition einer optimalen Parametereinstellung zur Klassifizierung ist für jeden Anwendungsfall erneut durchzuführen. Für eine automatisierte Parameteroptimierung finden Methoden wie z.B. Partikelschwarmoptimierung oder Genetische Algorithmen Anwendung. Dies ist Gegenstand aktueller Untersuchungen, v.a. mit dem Fokus, welche Methode für den hier

beschriebenen Anwendungsbereich geeignet ist und wie eine Ankopplung an die bestehenden Algorithmen erfolgt.

6 ZUSAMMENFASSUNG UND AUSBLICK

Die in diesem Paper vorgestellte Analyse-Methodik auf Basis von RSSI-Signalwerten bringt ein großes Forschungspotential mit sich. Wie in diesem Paper vorgestellt, greift die entwickelte Software-Architektur zur Datenaufnahme sowie -aufbereitung neben in der Forschung verbreitete Methoden des Signal Smoothing, Interpolation und

Signalkorrektur auch auf entwickelte und implementierte Regelsets sowie anwendungsspezifische Parameter zurück, um die benötigte Signal- bzw. Datengüte zu erreichen. Die gegebene Signalunschärfe konnte somit verbessert und dahingehend qualifiziert werden, dass diese in korrekte Distanzwerte überführbar ist, welche für die Prozesszuordnung sowie die Positionierung notwendig sind. Die Zielstellung eine Methodik zur effizienten, temporär durchführbaren Datenerhebung ist damit erfüllt. Die Technologie (Beacons, SMD) ist kostengünstig, den Anforderungen entsprechend konfigurierbar und leicht für die zu untersuchenden Produktionssysteme zu initialisieren.

Der Forschungsansatz eine automatische Erkennung logistischer Prozesse ausschließlich auf Basis der aufgenommenen Signalstärke- bzw. Entfernungsdaten zu ermöglichen, konnte mit Hilfe von überwachten Maschinellen Lernalgorithmen und gezielter Parameteranpassung mit einer hinreichenden Genauigkeit umgesetzt werden. Der bisher verfolgte Ansatz zeigt jedoch deutliche Schwächen bei komplexen logistischen Prozessen. Hier stoßen die Algorithmen an ihren Grenzen, was zu deutlich ungenaueren Prozesserkennung führt. Vor allem in den Übergangsbereichen zwischen aufeinanderfolgenden Prozessen kommt es sehr häufig zu fehlerhaften Klassenzuordnungen. Auch konnte nachgewiesen werden, dass eine Variation der Parametersets der einzelnen Algorithmen die Genauigkeit der Klassenzuordnung erhöht und diese vom jeweiligen Szenario abhängig sind, v.a. aber von der Komplexität des logistischen Prozesssystems. Die individuelle automatisierte Parameteroptimierung ist somit ein wesentlicher Schritt, für eine hohe und v.a. stabile Klassifizierungsgenauigkeit. Des Weiteren konnte die Eignung der ausgewählten Klassifizierungsalgorithmen für die zur Verfügung stehende Datenbasis nicht allgemeingültig bestätigt werden. Das bedeutet, dass die Leistungsfähigkeit der Klassifizierungsalgorithmen sehr stark je nach Untersuchungsszenario variiert. Hier können gezielte Kombinationen von Klassifizierungsalgorithmen (mit Boost-Algorithmen vgl. Li et al. [LWS08], mit Bagging-Algorithmen vgl. Quinlan [Qui96], Maclin et al. [MO97]) oder aus Fuzzy Logic und Klassifizierungsalgorithmen ([XWCG19], [CGMB12], [Iat12]) eine Verbesserung der Klassenzuordnung ermöglichen. Weitere Entwicklungsschritte sehen somit ein Ansatz vor, welcher nicht auf Maschinelle Lernalgorithmen zugreift, sondern einen Klassifizierungsalgorithmus darstellt, welcher ausschließlich auf einer Kombination aus Logik- und Prüfregelelementen basiert. Inwieweit es möglich ist, einen solchen Algorithmus für die Prozesszuordnung auf Basis der gegebenen Signalstärke- bzw. Entfernungsdaten zu erstellen, welcher zudem übertragbar auf definierte Prozessklassen ist unabhängig von entsprechenden Anwendungsszenario, ist aktuell Entwicklungsfokus. Herausforderung dabei ist die Definition der Prozessklassen sowie die Einbeziehung vorgelagerter und nachgelagerter Datensätze bzw. Prozessklassen. Die Ableitung von Regelsets, welche prozessbezogen sind, ist bereits erfolgreich umgesetzt. Zusätzlich kann hierbei weiterer Informationsinput die Prozesserkennung

positiv beeinflussen. Positionsdaten können die Genauigkeit der Klassenzuordnung erhöhen, wenn zusätzlich geeignete Regelsets genutzt werden. So können Positionsdaten mit Layoutdaten verknüpft und in den Algorithmus eingebunden werden, sodass die Prüfung der aktuellen Position Rückschlüsse auf mögliche Prozesse zulässt und in diesem Zug andere Prozesse ausschließen kann. Die Aufnahme bzw. Ablage eines Materialflussobjektes durch ein Fördermittel kann bspw. nicht in einem Bereich stattfinden, in dem keine Ablagefläche vorgesehen ist. Kritisch zu hinterfragen ist die Eignung der Regelsets hinsichtlich der Allgemeingültigkeit, vor allem wenn sich die Regeln auf Layout- bzw. Positionsdaten beziehen. Diesen sind zumeist abhängig vom Untersuchungsszenario und an individuelle Rahmenbedingungen geknüpft. Eine Standardisierung kann somit herausfordernd werden. Jedoch ist der Ansatz sehr vielversprechend.

Ein weiterer zu prüfender Ansatz ist nicht ausschließlich Layoutdaten für die Verbesserung der Positionsgenauigkeit zu hinterlegen, sondern auch die klassifizierten Signaldaten in Betracht zu ziehen. Somit wäre die die entgegengesetzte Vorgehensweise zu dem vorher beschriebenen Verfahren der Verbesserung der Prozesszuordnung mittels Positionsdaten.

7 FÖRDERHINWEIS

Dieses über die AiF geförderte Forschungsvorhaben wird im Rahmen des Programms zur Förderung der Industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Technologie, aufgrund eines Beschlusses des Deutschen Bundestages, gefördert.

Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie



aufgrund eines Beschlusses
des Deutschen Bundestages

LITERATUR

- [ALB19] Android Beacon Library: Distance Calculation. <https://altbeacon.github.io/android-beacon-library/distance-calculations.html>. Abgerufen:16.05.2019.
- [AGOP12] Anguita, D., Ghio, A., Oneto, L., Parra, X. & Reyes-Ortiz, J. L.: Human Activity Recognition on Smartphones Using a Multiclass Hardware-Friendly Support Vector Machine. In: Ambient assisted living and home care. [4th international workshop IWAAL 2012, 3.-5.12.2012, Vitoria-Gasteiz, Spanien]. Berlin: Springer, 2012. – ISBN: 9783642353949, S. 216-223
- [BSPD18] Baek, S. in, Shin, H. R., Park, M. H. & Doo, I. C.: A Study on the Management of Drug Logistics Using Beacon Technology. In: Advanced Science Letters, Vol. 24, Nr. 3, 2018. S.1979–1985
- [BHAD13] Blumrosen, G., Hod, B., Anker, T., Dolev, D. & Rubinsky, B.: Enhanced calibration technique for RSSI-based ranging in body area networks. In: Ad Hoc Networks, Vol. 11, Nr. 1, 2013, S. 555–569
- [BLM07] Bohonos, S., Lee, A., Malik, A., Thai, C. & Manduchi, R.: Universal Real-Time Navigational Assistance (URNA): An Urban Bluetooth Beacon for the Blind. In: Proceedings of the 1st ACM SIGMOBILE. [International workshop on Systems and networking support for healthcare and assisted living environments, 11.06.2007, San Juan]. New York: ACM, 2007. – ISBN: 978-1-59593-767-4, S. 83-87
- [Bro14] Brownlee, J.: Classification Accuracy is Not Enough: More Performance Measures You Can Use. <https://machinelearningmastery.com/classification-accuracy-is-not-enough-more-performance-measures-you-can-use/>, 2014, Abgerufen: 21.03.2019.
- [CGMB12] Cadenas, J. M., Garrido, M. C., Martínez, R. & Bonissone, P. P.: Extending information processing in a Fuzzy Random Forest ensemble. In: Soft Computing, Vol. 16, Nr. 5, 2012, S. 845–861. – DOI: 10.1007/s00500-011-0777-1
- [Cey16] Ceynowa, K.: „Leuchtfueher“ in der Bibliothek – Beacons-Technologie zur Indoor-Navigation in der Bayerischen Staatsbibliothek. In: Bibliothek - Forschung und Praxis, Vol. 40, Nr. 1, 2016. – DOI: 10.1515/bfp-2016-0009, S. 26-32
- [CCR18] Cronin, J. E., Cronin, S. M. & Reasner, N.: Interactive Seatlocalization beacon with customization. Patentschrift: US 9 870 585 B2, 2018.
- [DCK12] Dutt, V., Chaudhry, V. & Khan, I.: Pattern Recognition: an Overview. In: American Journal of Intelligent Systems, Vol. 2, Nr. 1, 2012, S. 23–27
- [EKGL14] Ellis, K., Kerr, J., Godbole, S., Lanckriet, G., Wing, D. & Marshall, S.: A random forest classifier for the prediction of energy expenditure and type of physical activity from wrist and hip accelerometers. In: Physiological measurement, Vol. 35, Nr. 11, 2012, S. 2191–2203. – DOI: 10.1088/0967-3334/35/11/2191
- [FZGX10] Fang, Z., Zhao, Z., Geng, D., Xuan, Y., Du, L. & Cui, X.: RSSI Variability Characterization and Calibration Method in Wireless Sensor Network. In: Proceedings of 2010 IEEE. [International Conference on Information and Automation (ICIA), 20.-23.06.2010, Harbin, China]. Piscataway, NJ: IEEE, 2010. – ISBN: 978-1-4244-5704-5, S. 1532–1537
- [FH16] Feldhorst, S. & ten Hompel, M.: Bewegungsklassifikation mithilfe mobiler Sensoren. In: Logistics Journal. Proceedings. Online. 2016. – DOI: 10.2195/lj_Proc_feldhorst_de_201605_01
- [Fro18] Frochte, J.: *Maschinelles Lernen. Grundlagen und Algorithmen in Python*. München: Hanser, 2018.
- [GFFM18] Giovanelli, D., Farella, E., Fontanelli, D. & Macii, D.: Bluetooth-based Indoor Positioning through ToF and RSSI Data Fusion. In: IPIN 2018. [9th International Conference on Indoor Positioning and Indoor Navigation, 24.-27.09.2018, Nantes, France]. Piscataway, NJ: IEEE, 2018. – ISBN: 978-1-5386-5635-8

- [Gir15] Girish, D.: RFID vs. iBeacon (BLE) Technology. <https://blog.beaconstac.com/2015/10/rfid-vs-ibeacon-ble-technology/>, 2015, Abgerufen: 15.05.2019.
- [GENS18] Groggert, S., Elser, H., Ngo, Q. H. & Schmitt, R. H.: Scenario-based Manufacturing Data Analytics with the Example of Order Tracing through BLE-Beacons. In: *Procedia Manufacturing*, Vol. 24, 2018. – DOI: 10.1016/j.promfg.2018.06.032, S. 243–249.
- [GWSF17] Groggert, S., Wenking, M., Schmitt, R. H. & Friedli, T.: Status Quo and Future Potential of Manufacturing Data Analytics – An Empirical Study. In: *Proceedings of the 2017 IEEE. [International Conference on Industrial Engineering & Engineering Management, 10.-13.12.2017, Singapore]*, Piscataway, NJ: IEEE, 2017. – ISBN: 978-1-5386-0948-4, S. 779-783
- [Gro06] Gronau, N.: Wirtschaftlichkeitsbetrachtung einer MES-Einführung. In: *IT Produktion*, 2006. S. 30–33
- [GSS14] Görz, G., Schneeberger, J. & Schmid, U.: *Handbuch der künstlichen Intelligenz*. München: Oldenbourg, 2014
- [HH17] Hartova, V. & Hart, J.: Livestock monitoring system using bluetooth technology. In: *Agronomy Research*, Vol. 15, Nr. 3, 2017. S. 707–712
- [Hee15] Hees, J.: Implementierung einer Android-App zur Suche nach Demenzerkrankten. Bachelorarbeit, Siegen, 2015.
- [Iat12] Iatan, I. F.: A Concurrent Fuzzy Neural Network Approach for a Fuzzy Gaussian Neural Network. In: *Proceedings of 10th World Congress on Computational Mechanics (WCCM 2012)*, Edgard Blücher: São Paulo, 2012. S. 3018-3025
- [inf18] infsoft GmbH: Indoor Tracking mit Display-Beacons in der Logistik. <https://www.infsoft.com/solutions/indoor-tracking>, 2019, Abgerufen: 16.05.2019.
- [JCLV16] Jayakody, J.A.D.C. A., Chathurangi, D., Lokuliyana, S. & Vithana, D.: Indoor Positioning: Novel Approach for Bluetooth Networks using RSSI Smoothing. In: *International Journal of Computer Applications*, Vol. 137, Nr. 13, 2016, S. 26–32
- [LWS08] Li, X., Wang, L. & Sung, E.: AdaBoost with SVM-based component classifiers. In: *Engineering Applications of Artificial Intelligence*, Vol. 21, Nr. 5, 2008, S. 785–795
- [KMK16] Kriz, P., Maly, F. & Kozel, T.: Improving Indoor Localization Using Bluetooth Low Energy Beacons. In: *Mobile Information Systems*, 2016. – DOI: 10.1155/2016/2083094, S. 1–11.
- [Köp14] Köppe, E.: *Lokalisierung sich bewegnender Objekte innerhalb und außerhalb von Gebäuden*. Dissertation, Berlin, 2014.
- [Kün08] Küng, R.: Kapitel 2: Ausbreitung von Radiowellen I. <https://home.zhaw.ch/kunr/NTM1/unterlagen/>, 2008, Abgerufen: 17.05.2019.
- [LKGS17] Lindner, F., Kostyszyn, K., Grunert, D. & Schmitt, R.: Smart Devices in der Fertigung. Neue Akteure in der industriellen Kommunikation. In: *ZWF - Zeitschrift für wirtschaftlichen Fabrikbetrieb*, Vol. 112, Nr. 10, 2017, S. 662–665
- [MO97] Maclin, R. & Opitz, D.: An empirical evaluation of bagging and boosting. In: *AAAI'97/IAAI'97 Proceedings of the 14th National Conference on Artificial Intelligence and 9th Innovative Applications of Artificial Intelligence Conference*. 27.-31.07.1997, Providence, Rhode Island, Menlo Park, Calif.: AAAI Press/The MIT Press, 1997. – ISBN: 0262510952, S. 546–551
- [Mar14] Martin, H.: *Transport- und Lagerlogistik. Planung, Struktur, Steuerung und Kosten von Systemen der Intralogistik*. Wiesbaden: Springer Vieweg, 2011. – ISBN: 978-3-658-03142-8
- [Mat12] Matern, M.: Der Einsatz der Multimoment-Aufnahme zur Erfassung und Bewertung der Prozesskosten einer Krankenhausapotheke. In: *Zukunftsperspektiven der Gesundheitswirtschaft*. Berlin: LIT, 2012. – ISBN: 978-3-643-11415-0, S. 98-106

- [Moo16] Moody, M.: Analysis of Promising Beacon Technology for Customers. In: *Elon Journal of Undergraduate Research in Communication*, Vol. 1, Nr. 6, 2015.
- [PGGC17] Pavey, T. G., Gilson, N. D., Gomersall, S. R., Clark, B. & Trost, S. G.: Field evaluation of a random forest activity classifier for wrist-worn accelerometer data. In: *Journal of science and medicine in sport*, Vol. 20, Nr. 1, 2017, S. 75–80
- [PEKM06] Pärkkä, J., Ermes, M., Korpipää, P., Mäntyjärvi, J., Peltola, J. & Korhonen, I.: Activity Classification Using Realistic Data From Wearable Sensors. In: *IEEE Transactions on Information Technology in Biomedicine*. Vol. 10, Nr. 1, 2006, S. 119–128
- [Qui96] Quinlan, J. R.: Bagging, boosting, and C4.5. In: *AAAI'96 Proceedings of the 13th national conference on Artificial intelligence - Volume 1*. 04.-08.08.1996, Portland, Oregon, Menlo Park, Calif.: AAAI Press, 1996. – ISBN: 026251091X, S. 725–730
- [RLJA15] Rida, M. E., Liu, F., Jadi, Y., Algawhari, A. A. A. & Askourih, A.: Indoor Location Position Based on Bluetooth Signal Strength. In: *2015 2nd International Conference on Information Science and Control Engineering*, IEEE, 2015, S. 769–773
- [ST18] Satan, A. & Toth, Z.: Development of Bluetooth based indoor positioning application. In: *Proceedings of 2018 IEEE. [International Conference on Future IoT Technologies (Future IoT)*, 18.-19.01.2018, Eger, Ungarn], Piscataway, NJ: IEEE, 2018. – ISBN: 978-1-5386-1208-8, S. 1–6
- [Sch19] Schnabel, P.: Elektromagnetische Wellen und Felder. <https://www.elektronik-kompodium.de/sites/grd/1403021.htm>. Abgerufen: 17.05.2019.
- [SL18] scikit-learn: Documentation of scikit-learn. https://scikit-learn.org/stable/supervised_learning.html, 2018. Abgerufen: 01.04.2019
- [Tab10] Tabbane, S.: *Handbook of mobile radio networks*. Boston: Artech House, 2010. – ISBN: 9781580530095
- [VDI17] VDI-Gesellschaft Produktion und Logistik: *VDI 2492: Multimomenthäufigkeitsverfahren (MMH-Verfahren) in der betrieblichen Praxis*. Beuth Verlag, 2017.
- [WDT15] Walse, K. H., Dharaskar, R. V. & Thakare, V. M.: A Study of Human Activity Recognition using Adaboost Classifier on WISDM Dataset. In: *The IIOAB Journal*, Vol. 7, Nr. 2, 2016, S. 68–76
- [WHC07] Wu, Y., Hu, J. & Chen, Z.: Radio Map Filter for Sensor Network Indoor Localization Systems. In: *5th IEEE International Conference on Industrial Informatics*, 23.-27.07.2007, Wien, Österreich, Piscataway, NJ: IEEE, 2007. – ISBN: 978-1-4244-0850-4, S. 63–68
- [XWCG19] Xue, J., Wu, C., Chen, Z., van Gelder, P.H.A.J.M. & Yan, X.: Modeling human-like decision-making for inbound smart ships based on fuzzy decision trees. In: *Expert Systems with Applications*, Vol. 115, 2019, S. 172–188. – DOI: 10.1016/j.eswa.2018.07.044
- [ZOSP17] Zhao, J., Olivieri, H., Seppänen, O., Peltokehti, A., Badihi, B. & Lundström, P.: Data Analysis on Applying Real Time Tracking in Production Control of Construction. In: *Proceedings of the 2017 IEEE. [International Conference on Industrial Engineering & Engineering Management*, 10.-13.12.2017, Singapore], Piscataway, NJ: IEEE, 2017. – ISBN: 978-1-5386-0948-4, S. 573–577
- [ZYLQ17] Zhou, C., Yuan, J., Liu, H. & Qiu, J.: Bluetooth Indoor Positioning Based on RSSI and Kalman Filter. In: *Wireless Personal Communications*, Vol. 96, Nr. 3, 2017, S. 4115–4130
- [Zwi14] Żwirko, Ł.: *Realization Limits of Impulse-Radio UWB Indoor Localization Systems*. Dissertation in: *Karlsruher Forschungsberichte aus dem Institut für Hochfrequenztechnik und Elektronik*, Vol. 71, Karlsruher Institut für Technologie (KIT), 2014.

Madlin Müller, M. Sc., Research Assistant at the Chair of Material Handling, Technische Universität (TU) Dresden

since 2014. Madlin Müller was born 1988 in Dipoldiswalde, Germany. Between 2007 and 2014 she studied Industrial Engineering at the TU Dresden. In addition to the development of a temporary analysis system for logistic processes, her research field also includes the optimization of inaccurate data, the use of data mining methods for targeted data analysis and process optimization in production and logistics.

Address: Technische Universität Dresden, Professur für Technische Logistik, 01062 Dresden, Germany, Phone: +49 351 463-37604, Fax: +49 351 463-35499, E-Mail: madlin.mueller@tu-dresden.de

Dipl.-Ing. Mathias Kühn, Research Assistant at the Chair of Material Handling, TU Dresden. Between 2007 and 2014 he studied Mechanical Engineering at the TU Dresden. His field of research includes the simulation based optimization for solving scheduling problems.

Address: Technische Universität Dresden, Professur für Technische Logistik, 01062 Dresden, Germany, Phone: +49 351 463-32112, Fax: +49 351 463-35499, E-Mail: mathias.kuehn@tu-dresden.de

Prof. Dr.-Ing. habil. Thorsten Schmidt, Head of the Chair of Material Handling, TU Dresden. Prof. Thorsten Schmidt is full professor at the TU Dresden and heads the Chair of Material Handling at the Mechanical Engineering faculty since 2008. He holds a diploma de-gree in Mechanical Engineering (TU Dortmund) and a master degree in Industrial Engineering (Georgia Institute of Technology). He received his Ph.D. from the TU Dortmund in 2001. His current research interests include energy-efficient control strategies in material flow, formal verification of control logic, power analysis of distributed and self-controlled systems, lightweight structures in material flow, and stress analysis of wire ropes and timing belts.

Address: Technische Universität Dresden, Professur für Technische Logistik, 01062 Dresden, Germany, Phone: +49 351 463-32538, Fax: +49 351 463-35499, E-Mail: thorsten.schmidt@tu-dresden.de