

# Bewegungsklassifikation mithilfe mobiler Sensoren zur Analyse des Kommissionierprozesses

Motion Classification of the Order Picking Process using Mobile Sensors

Sascha Feldhorst  
Michael ten Hompel

Lehrstuhl für Förder- und Lagerwesen  
Fakultät Maschinenbau  
Technische Universität Dortmund

**I**n diesem Beitrag wird eine neue Methode zur Analyse des manuellen Kommissionierprozesses vorgestellt, mit der u. a. die Kommissionierzeitanteile automatisch erfasst werden können. Diese Methode basiert auf einer sensorgestützten Bewegungsklassifikation, wie sie bspw. im Sport oder in der Medizin Anwendung findet. Dabei werden mobile Sensoren genutzt, die fortlaufend Messwerte wie z. B. die Beschleunigung oder die Drehgeschwindigkeit des Kommissionierers aufzeichnen. Auf Basis dieser Daten können Informationen über die ausgeführten Bewegungen und insbesondere über die durchlaufenen Bewegungszustände gewonnen werden. Dieser Ansatz wird im vorliegenden Beitrag auf die Kommissionierung übertragen. Dazu werden zunächst Klassen relevanter Bewegungen identifiziert und anschließend mit Verfahren aus dem maschinellen Lernen verarbeitet. Die Klassifikation erfolgt nach dem Prinzip des überwachten Lernens. Dabei werden durchschnittliche Erkennungsraten von bis zu 78,94 Prozent erzielt.

[Schlagwörter: Bewegungsklassifikation, Kommissionierung, Kommissionierzeitanteile, Mobile Sensoren, Maschinelles Lernen]

**A**bstract: This contribution introduces a new methodology to analyze the manual order picking process in warehouses. The approach relies on a sensor-based motion classification which is already used in other domains like sports or medical science. Thereby, different sensor data, e. g. accelerations or rotation rates are continuously recorded during the order picking. With help of this data the motion can be analysed to identify different motion states. Therefore, this paper defines all relevant motion states within the order picking process. These states are part of a classification system which works with methodologies from the field of machine learning. The classification is done with a supervised learning approach which achieves an accuracy of up to 78,94 percent.

[Keywords: Motion Classification, Order Picking, Mobile Sensors, Machine Learning]

## 1 EINLEITUNG

Auch wenn die vierte industrielle Revolution bereits ausgerufen wurde und Fachleute davon ausgehen, dass zukünftig cyber-physische Systeme (CPS) die Produktion und Logistik in den Unternehmen lenken [HVB14, S.15], ist der Mensch nach wie vor ein wichtiger Bestandteil industrieller Prozesse. Insbesondere in der Kommissionierung wird sich der Mensch aufgrund seiner kognitiven und motorischen Fähigkeiten auch in CPS-basierten Logistikanlagen mittelfristig nicht wirtschaftlich durch Maschinen ersetzen lassen. Deshalb wird die Kommissionierung auch zukünftig einen personalintensiven Prozess darstellen und in Hochlohnländern wie Deutschland mit signifikanten Kosten verbunden sein. Entsprechend bleibt sie Gegenstand von Rationalisierungsbestrebungen und Optimierungsvorhaben seitens ihrer Betreiber [tSB11, S.3].

Bei der Optimierung von Kommissioniersystemen und auch bei deren Neuplanung spielt die Kenntnis der Dauer von manuellen Tätigkeiten eine wichtige Rolle. Genaue Zeitwerte erleichtern nicht nur die Modellierung der logistischen Tätigkeiten, sondern auch die Dimensionierung des Arbeitskräftebedarfs und der Puffergrößen [KSS<sup>+</sup>10, S.5]. Allerdings gestaltet sich insbesondere bei den Kommissionierzeitanteilen, die für die Leistungsbestimmung wichtige Einflussparameter darstellen, eine Quantifizierung schwierig. Verfahren zur Vorgabezeitbestimmung wie REFA oder *Methods-Time Measurement* (MTM) erlauben nur Aussagen zur mittleren Dauer von Arbeitsvorgängen [KSS<sup>+</sup>10, S.5]. Zudem werden bestimmte Leistungsfaktoren wie z. B. das Artikelgewicht von diesen Verfahren nur unzureichend berücksichtigt. Beispielsweise wird die maximal wählbare Kraft im MTM-Verfahren in realen Kommissioniersystemen häufig überschritten [SSW14]. Die Bestimmung der Bearbeitungszeit mit diesen Verfahren liefert deshalb in der praktischen Anwendung nur Näherungslösungen mit einer gewissen Unschärfe. Die Steigerung der Genauigkeit ist zwar möglich (z. B. durch die Aufnahme und Auswertung von Prozessvideos), aber mit einem unverhältnismäßig hohen Aufwand

verbunden, der im Rahmen von vielen Industrieprojekten nicht betrieben werden kann. Auch aus den Datenbanken der betrieblichen *Warehouse-Management-Systeme* (WMS) kann erfahrungsgemäß nur im Mittel bestimmt werden, wie viele Picks pro Stunde oder Positionen pro Tag kommissioniert werden. Selbst die Auswertung von automatisch erstellten Tätigkeitsprotokollen, wie sie von Kommissionierleitsystemen angelegt werden können, erlaubt keine genaue Ermittlung der individuellen Weg- und Totzeiten oder der Pickstruktur. Dieser Umstand erschwert nicht nur die Bestimmung der Leistungsfähigkeit eines bestehenden Kommissioniersystems, sondern ebenfalls die Auswahl von geeigneten Systemtypen während der Planungsphase. Auch die Abbildung des menschlichen Faktors in der Erstellung von Simulationsmodellen ist davon betroffen [GS11].

In dem vorliegenden Beitrag wird deshalb eine neue Methode zur Analyse des manuellen Kommissionierprozesses vorgestellt, mit der u. a. die Kommissionierzeitannteile automatisch erfasst werden können. Dabei werden mobile Sensoren genutzt, die fortlaufend Messwerte wie z. B. die Beschleunigung [ $\text{m/s}^2$ ] oder die Drehgeschwindigkeit [ $\text{rad/s}$ ] des Kommissionierers aufzeichnen. Die Methode gliedert sich grundsätzlich in die Schritte Datenerfassung, Bewegungsklassifikation, Aktivitätserkennung und Zeitanalyse. Nach der Aufzeichnung und Vorverarbeitung der Daten werden zunächst die grundlegenden Bewegungszustände und deren zeitliche Abfolge identifiziert. Darauf aufbauend ermittelt eine Aktivitätserkennung die den Bewegungen zugehörigen logistischen Tätigkeiten. Der Fokus dieses Beitrags liegt auf der sensorgestützten Bewegungsklassifikation und ersten Evaluierungsergebnissen, die im Rahmen einer prototypischen Implementierung und einer Vorstudie gewonnen werden konnten.

Der Beitrag gliedert sich insgesamt in fünf Teile: Nach einer thematischen Einordnung und der Abgrenzung von bestehenden Lösungen wird zunächst das Gesamtkonzept vorgestellt. Anschließend werden der Lösungsansatz und wichtige Grundüberlegungen beschrieben, die der Bewegungsklassifikation zugrunde liegen. Nach einigen Implementierungsdetails schließt der Beitrag mit den Evaluierungsergebnissen sowie einem Fazit und Ausblick.

## 2 STAND DER TECHNIK

Mit der zunehmenden Miniaturisierung von integrierten, kostengünstigen und mobilen Sensoren rücken auch die Themen der Bewegungsklassifikation und der Aktivitätserkennung in den letzten Jahren verstärkt in den Fokus von Wissenschaft und Wirtschaft. Dies manifestiert sich u. a. im Freizeit-, Unterhaltungs- und Fitnessbereich [AB14]. Dort werden Mobiltelefone, Uhren, Armbänder oder sogar Kleidungsstücke mit Sensorik ausgestattet und dazu genutzt, die körperlichen Aktivitäten der Nutzer zu quantifizieren, aufzuzeichnen und auszuwerten [LYA09],

[PEK<sup>+</sup>06], [TTM06], [LKA<sup>+</sup>06]. Die verfügbaren Produkte aus dem Fitnessbereich protokollieren bspw., wie lange sich eine Person in den unterstützten Bewegungszuständen befindet, um daraus abzuleiten, ob ausreichend körperliche Bewegung im Laufe eines Tages stattgefunden hat. Ergänzt werden diese Daten häufig durch Vitalwerte wie die Herzfrequenz [TIH<sup>+</sup>07], [ZCA12], die u. a. die Bestimmung des Kalorienverbrauchs unterstützen. Entsprechende Vitalwertensoren werden mittlerweile direkt in die mobilen Endgeräte (auch *Wearables* genannt) integriert. Prominente Vertreter dieser Produkte sind die *Apple Smart Watch*, die *Samsung Gear S2* oder die *Motorola 360*. Speziell im Ausdauersportbereich (Radfahren, Laufen oder Schwimmen) wird das Angebot durch zahlreiche Multi-sportcomputer ergänzt. Während im Fitnessbereich die Quantifizierung von Schritten und die daraus abgeleitete Abschätzung von zurückgelegten Distanzen und verbrannten Kalorien im Vordergrund stehen, unterstützen Multi-sportcomputer eine detailliertere Auswertung der ausgeführten Bewegungen. Um die Auswertung zu unterstützen, wird häufig auch mit sportspezifischen Zusatzsensoren gearbeitet, die bspw. direkt am Laufschuh oder am Fahrrad befestigt werden [Pol15], [Gar15]. Auch im Leistungssportbereich kommen sensorbasierte Analyseverfahren bereits seit längerem zum Einsatz. In [HLM<sup>+</sup>15] wird beispielsweise ein Ansatz vorgestellt, um mithilfe von Sensorik die Trainingsaktivitäten von Eishockeyspielern zu erfassen und über einen längeren Zeitraum zu überwachen. Vergleichbare Lösungen gibt es auch im Fußball, beim Schwimmen oder in der Leichtathletik [BKL05], [BFS<sup>+</sup>08], [MS05], [AGR<sup>+</sup>02].

Für die Erkennung menschlicher Aktivitäten im Bereich des *Ubiquitous Computing* werden als Datenquelle i. d. R. Smartphones und die integrierte Sensorik herangezogen. In den verfügbaren Veröffentlichungen werden häufig Lösungen vorgestellt, die alltägliche Aktivitäten wie Busfahren oder Einkaufen und die damit verbundenen Bewegungszustände wie Sitzen, Liegen, Stehen oder Treppesteigen erfassen und diese direkt auf dem Gerät erkennen [AGO<sup>+</sup>12], [LC11]. Meist wird auf eine Kombination aus Beschleunigungs- und Ortungsdaten aus globalen Navigationssatellitensystemen wie GPS oder GLONASS zurückgegriffen. Ein verbreitetes Teilproblem in diesem Bereich ist die sogenannte *Transport Mode Identification*. Dabei wird automatisch bestimmt, mit welchen Verkehrsmitteln (Bus, Zug, Auto, zu Fuß) sich eine Person im Laufe des Tages fortbewegt [HNT13], [SH15], [WCM10]. Die Mobilität von Menschen und die Vielfältigkeit der Tätigkeiten im täglichen Leben ist eine große Herausforderung für die Aktivitätserkennung. Dies zeigt sich insbesondere im großen Analyse- und Annotationsaufwand, der beim Anlernen der eingesetzten Verfahren entsteht [ZHY09]. Abhängig von der Umgebung und den zu unterscheidenden Aktivitäten kann aus einer Vielzahl von Verfahren gewählt werden, deren Eignung sich je nach Anwendung stark unterscheiden kann. Deshalb sind viele der verfügbaren Lö-

sungen stark an die unterstützten Aktivitäten oder den Kontext angepasst und lassen sich nicht ohne Mehraufwand auf einen anderen Bereich übertragen. Die automatische Übertragung angelernter Verfahren auf eine andere Anwendung ist eine offene Forschungsfrage, die aktiv bearbeitet wird, bspw. durch die Anwendung von Verfahren des teil- oder unüberwachten maschinellen Lernens [KKB14], [TMC<sup>+</sup>13]; [TMA<sup>+</sup>12], [HZY11], [YCI<sup>+</sup>09].

Vor allem im medizinischen Bereich ist die sensorgestützte Analyse von menschlichem Verhalten und den damit verbundenen Bewegungen Gegenstand verschiedener Forschungstätigkeiten. Die Analyseergebnisse werden hier u. a. zur Symptomerkennung und Überwachung der Rekonvaleszenz verschiedener Krankheiten eingesetzt. Beispielsweise finden Verfahren der Mustererkennung in der Behandlung von Herz-, Parkinson- und Schlaganfallpatienten Verwendung [BSK<sup>+</sup>07], [DXB<sup>+</sup>11], [ZMH<sup>+</sup>12], [MHZ<sup>+</sup>12]. Darüber hinaus stellt auch das Thema *Ambient Assisted Living* (AAL) in diesem Zusammenhang ein sehr aktives Forschungsfeld dar. AAL verfolgt das Ziel, mit technischen Systemen und geeigneten Methoden hilfsbedürftigen Menschen bis ins hohe Alter eine selbstständige Lebensweise zu ermöglichen [BHR12]. Dafür werden der Lebensraum und auch die Menschen selbst mit entsprechenden technischen Artefakten ausgestattet, die u. a. dabei helfen, anormale und bedrohliche Lebenslagen (z. B. medizinische Notfälle) zu bemerken und angemessene Maßnahmen einzuleiten. So wird bspw. mit Indoor-Ortungssystemen (engl. *Real-time Location System RTLS*) das Bewegungsverhalten der Bewohner erfasst [JKK14], um daraus mit Verfahren der Mustererkennung Verhaltensmodelle abzuleiten, die zur automatischen Überwachung des Bewohners herangezogen werden können [FBG<sup>+</sup>13]. Die automatische Erkennung von Verhalten und Aktivitäten wird als Teilbereich von AAL häufig unter dem Begriff *Activities of Daily Life Monitoring* (ADL-Monitoring) zusammengefasst [ZBB<sup>+</sup>08]. Darüber hinaus behandelt AAL auch die Entwicklung von Sensorik, deren Platzierung und Vernetzung, die Erprobung neuer Überwachungsmethoden sowie die Erkennung von Anomalien (z. B. von Stürzen) [BAK<sup>+</sup>14], [HMK<sup>+</sup>14].

Auch im industriellen Bereich gibt es verschiedene verwandte Arbeiten, die sich entweder mit der Analyse und Optimierung von Leistungsaspekten des manuellen Kommissionierprozesses oder der Nutzung von mobilen Sensoren in industriellen Prozessen beschäftigen. Arbeiten, die beide Aspekte auf Basis realer Prozessdaten miteinander vereinen, sind den Autoren derzeit nicht bekannt. Im Rahmen des Forschungsprojekts *Beschreibung der Dynamik manueller Operationen in logistischen Systemen* wurden die statistischen Eigenschaften der Dauer von manuellen Handhabungsvorgängen sowie die Modellierung der Vorgangsdauer durch Wahrscheinlichkeitsverteilungen betrachtet [KSS<sup>+</sup>10]. Dabei ging es insbesondere darum, für die Planung die generalisierten Aussagen der heute ein-

gesetzten Zeitbestimmungsverfahren (wie z. B. REFA oder MTM) zu verbessern. Zudem wurden verschiedene Faktoren, wie der Übungsgrad oder das Entlohnungssystem identifiziert, die einen Einfluss auf die Dauer von Handhabungsvorgängen haben können. Die Zielsetzung dieses Projekts unterstreicht die Wichtigkeit von gesicherten Erkenntnissen über die Dauer von manuellen Tätigkeiten und liefert damit auch die Motivation für das hier vorgestellte Verfahren. Neben allgemeinen Zeit- und Leistungswerten ist auch die mitarbeiterspezifische Leistung für den operativen Betrieb und die Steuerung von manuellen Kommissioniersystemen von Interesse. Deshalb wird in [Sie13] ein kennzahlenbasiertes Verfahren für die Person-zur-Ware-Kommissionierung vorgestellt. Mithilfe des Verfahrens sollen die Leistungsgrade einzelner Mitarbeiter quantifiziert und bewertet werden. Für die Beurteilung der individuellen Kommissionierleistung ist jedoch eine Erhebung der reinen Bearbeitungszeit (ohne Zusatztätigkeiten) und die Einhaltung einer im Vorfeld festgelegten Wegstrategie erforderlich, da die einzelnen Ergebnisse ansonsten verfälscht werden [Sie13]. Aufbauend auf diesen Ergebnissen wurden im Zuge des Forschungsprojekts *EfKom* Einflussfaktoren identifiziert, die sich auf die Leistung auswirken. Diese Informationen wurden ebenfalls mitarbeiterbezogen erhoben und sollten u. a. der Optimierung der Personaleinsatzplanung dienen [SSW14]. Während alle bereits vorgestellten Arbeiten in diesem Bereich sich der Problemstellung von statistischer Seite nähern, beschreitet das Forschungsprojekt *KomPlanVR* einen anderen Weg. In diesem Projekt wurde eine Methode zur Planung, Bewertung und Optimierung manueller Kommissioniersysteme entwickelt, welche die Möglichkeiten der *Virtual-Reality*-Technologie (VR-Technologie) und realitätsnaher Bewegungsabläufe miteinander kombinieren soll [GS11]. Dabei werden Kennzahlen zur Leistungsbewertung und insbesondere Kommissionierzeitanteile mithilfe eines VR-basierten Simulators im Labor ermittelt. Der Kommissionierer wird bei diesem Ansatz mit einer VR-Brille ausgestattet, über die er das virtuelle System sehen kann, in dem er arbeitet. Die Fortbewegung durch das Lager wird durch ein umgebautes Laufband abgebildet und die Greifbewegungen durch spezielle Handschuhe erfasst. Parallel zu jedem Simulationslauf werden die einzelnen Zeitanteile fortlaufend gemessen. Die veröffentlichten Ergebnisse, die mittels einer prototypischen Realisierung ermittelt wurden, offenbaren die Komplexität einer realitätsnahen Abbildung des Kommissionierprozesses. Dies zeigt sich u. a. in Abweichungen der Simulationsergebnisse von den realen Prozesswerten.

Arbeiter in industriellen Prozessen mit mobilen Sensoren auszustatten, ist ein Ansatz, der insbesondere im Bereich Ergonomie, Arbeitssicherheit und Assistenzsysteme bereits vielfältig Anwendung findet. Beispielsweise wurde im Rahmen des Forschungsprojekts *ErgoKom* ein Konzept zur automatisierten, fortlaufenden Belastungsermittlung für die manuelle Kommissionierung erarbeitet und als Funktionsmuster umgesetzt. Das Konzept nutzt eine 3D-

Kamera und Inertialsensorik zur Erfassung der Körperhaltungen des Kommissionierers. Darüber hinaus wird auf industrielle Sensoren, die *Pick-by-Vision*-Technologie und Daten aus einem *Warehouse-Management-System* zurückgegriffen [GDR<sup>+</sup>14]. Im Bereich Arbeitssicherheit wird mithilfe von Sensoren u. a. die Anwesenheit in Gefahrenbereichen erkannt oder die aktuelle Belastung von Arbeitern (z. B. durch Hitze) überwacht, um Unfälle und Überlastungen zu verhindern [LL09], [RC11], [PEH<sup>+</sup>14], [PAH<sup>+</sup>15]. In Assistenzsystemen dagegen bilden Sensoren, die am Körper getragen oder in der Arbeitsumgebung angebracht werden, die Grundlage zur Realisierung einer kontextsensitiven Informationsbereitstellung [Wöl14].

Letztlich unterstreichen alle vorgestellten Forschungsarbeiten aus diesem Bereich den Bedarf nach validen Zeitwerten für manuelle Tätigkeiten in der Kommissionierung, da sie entweder von diesen Werten abhängig sind oder versuchen, diese durch den Einsatz von Simulationstechnik möglichst genau zu ermitteln. Ursächlich dafür ist der hohe Aufwand, der mit der Messung der Zeitwerte in realen Systemen verbunden ist bzw. der verallgemeinernde Charakter heute eingesetzter Zeitbestimmungsverfahren. Auf Basis dieser Beobachtung wird in diesem Beitrag die Grundlage gelegt, Zeitwerte automatisch direkt aus dem Prozess zu messen, um so eine valide Basis für die Analyse von bestehenden Kommissioniersystemen zu schaffen. Durch die Bildung verschiedener Systemtypen, z. B. nach Sortiment oder der Art von Zusatzfähigkeiten, und den Aufbau entsprechender Datenbanken, ist es mit dem vorgeschlagenen Ansatz auch möglich, die Leistungsprognosen im Rahmen von Neuplanungen zu verbessern. Damit hat der vorgestellte Ansatz das Potenzial, die Leistungsbestimmung von Kommissioniersystemen von der operativen Steuerung (z. B. Personaleinsatzplanung) über die Optimierung bestehender Systeme bis hin zur Planung zu verbessern.

### 3 GESAMTKONZEPT

Im Gegensatz zur Erkennung menschlicher Aktivität in alltäglichen Vorgängen mit unbestimmten Kontext haben Kommissionierprozesse zwei entscheidende Vorteile. Zum einen laufen sie deutlich strukturierter und vorhersehbarer ab. Strukturiert meint hier, dass sich logistische Aktivitäten i. d. R. aus wiederkehrenden Bewegungen zusammensetzen, die sequenziell durchlaufen werden und logisch ein klar erkennbares Muster haben. Beispielsweise wird die Position eines Kommissionierauftrags nach dem Person-zur-Ware-Prinzip häufig wie folgt abgearbeitet: gehen zum Entnahmeort, anhalten und sich drehen, Lagerfach scannen, Artikel entnehmen, Artikel auf Kommissionierwagen ablegen, Entnahme quittieren und weitergehen. Zum anderen sind in der Kommissionierung viele Tätigkeiten stark ortsgebunden, d. h. ein Auftrag wird an der Basis angenommen und abgegeben, oder eine Auftragsposition wird in einer Lagergasse gepickt. Deshalb ist zu erwarten, dass sich

bei dieser Anwendung mithilfe einer sensorbasierten Aktivitätserkennung gute Ergebnisse erzielen lassen.

Bei der Erkennung menschlicher Aktivitäten können verschiedene Detaillierungsstufen betrachtet werden. Diese reichen von einfachen Bewegungszuständen wie Sitzen, Laufen oder Fahren bis hin zu komplexen Tätigkeiten wie Einkaufen, Kochen oder Arbeiten. Die Wahl der Granularität richtet sich vor allem nach der Anwendung und den zu erfüllenden Anforderungen. Um die Bearbeitungszeit von Kommissionieraufträgen zu bestimmen, muss die Granularität so gewählt werden, dass aus den Ergebnissen des entwickelten Verfahrens die einzelnen Kommissionieranteile ermittelt werden können. Zu diesen zählen die Basis-, Weg-, Tot- und Greifzeit [Gud05, S.762]. Die Basiszeit umfasst alle Tätigkeiten, welche der Kommissionierer vor Beginn und nach Abschluss eines Rundgangs durch das Lager verrichtet [GS11, S.48]. Dazu gehören die Übernahme eines Auftrags oder das Sortieren von Belegen sowie weitere Informations-, Warte- und Handhabungsvorgänge [Gud05, S.762], [Sad07, S.82]. Dieser Teil des Prozesses beinhaltet verschiedene Aktivitäten, die aus mehreren Schritten bestehen und sich aus mehreren Bewegungsfolgen zusammensetzen. Die Wegzeit besteht im Vergleich dazu aus sehr einfachen Bewegungen wie Gehen oder Fahren, die ähnlich wie Zustände meist über einen längeren Zeitraum eingenommen werden. Deshalb muss im Fall der manuellen Kommissionierung sowohl mit einzelnen Bewegungen als auch mit komplexeren Aktivitäten gearbeitet werden. Um mit dieser unterschiedlichen Komplexität umzugehen, führen andere Arbeiten auf diesem Gebiet Abstraktionsebenen ein [Har11, S.21], [Sii15, S.15f.]. Dabei werden meist zwei oder drei Ebenen hierarchisch angeordnet, wobei eine Ebene stets auf den Ergebnissen der darunterliegenden Ebenen aufbaut. Auf der untersten Ebene werden ausschließlich einfache Aktivitäten betrachtet, die durch einzelne oder einige wenige Bewegungen gekennzeichnet sind. Auf den darüberliegenden Ebenen dagegen wird mit komplexeren Aktivitäten gearbeitet. Dabei werden die Aktivitäten der untersten Ebene meist direkt aus den Sensorwerten abgeleitet, und die Aktivitäten der höheren Ebenen setzen sich aus den Aktivitäten der darunterliegenden Ebene zusammen. In dem vorgestellten Ansatz wird mit drei Abstraktionsebenen gearbeitet (vgl. Abb. 1). Zur einfacheren Unterscheidung werden im Folgenden Entitäten der unteren Methodenebene als Bewegungen und Entitäten der oberen Methodenebene als logistische Aktivitäten bezeichnet.

Wie eingangs erwähnt, bilden Sensoren das Fundament der hier vorgestellten Methode. Sie nehmen physikalische Größen direkt aus dem Prozess auf. Je nach Art des Sensors werden die Rohdaten nach der Aufnahme bereits innerhalb der Sensoreinheit vorverarbeitet. Im Zuge dessen kommen u. a. Verfahren zum Einsatz, welche die Qualität der Daten verbessern oder die Datenbasis erweitern.



Abbildung 1. Abstraktionsebenen der Methode

Beispielsweise kann durch einen erweiterten Kalmanfilter die Orientierung des Sensors im Raum abgeschätzt werden [Sab06]. Davon wird in diesem Beitrag jedoch noch kein Gebrauch gemacht. Nach der Datenaufnahme müssen die gewonnenen Prozessdaten persistent gespeichert werden. Anschließend werden diese Daten von einer Bewegungsklassifikation weiterverarbeitet. Die Klassifikation erfolgt nach dem Prinzip des überwachten Lernens (engl. *Supervised-Learning*). Vor dem eigentlichen Betrieb werden aus bereits annotierten Sensordaten (sog. Trainingsdaten) quantifizierbare Merkmale wie die Standardabweichung extrahiert und ein Modell gebildet. Mithilfe des Modells können die im Betrieb aufgenommenen Daten einzelnen Bewegungen (wie Greifen) oder Bewegungszuständen (wie Gehen) zugeordnet werden. Wie das Modell berechnet bzw. angewendet wird oder wie zuverlässig es arbeitet, ist abhängig vom eingesetzten Klassifikationsverfahren. Die Ausgabe dieser Methodenebene sind die aus den Sensordaten identifizierten Bewegungen sowie deren zeitliche Dauer und Abfolge. Im nächsten Schritt ist geplant, die Ergebnisse der Bewegungsklassifikation mithilfe einer Aktivitätserkennung weiterzuverarbeiten. Auch hier kann mithilfe des maschinellen Lernens nach Mustern in den Eingabedaten gesucht werden. Dazu sollen Folgen von Bewegungszuständen und Kontextinformationen (z. B. aus dem Prozess oder dem WMS) zusammengefasst werden, um komplexere Tätigkeiten wie Kommissionieren oder Beschicken zu identifizieren. Da auf dieser Ebene nur noch mit Zuständen gearbeitet wird, bietet sich der Einsatz anderer Verfahren, wie z. B. der *Hidden-Markov-Modelle* an. Abschließend werden die logistischen Aktivitäten und ihre zeitlichen Eigenschaften auf der obersten Methodenebene verdichtet, analysiert und bewertet. Die Hauptaufgabe auf dieser Ebene ist es, aus den Kommissionierzeitanteilen relevante Leistungskennzahlen abzuleiten und diese sowohl pro Kommissionierer als auch prozessweit darzustellen. Werden diese Daten über einen längeren Zeitraum erfasst, können daraus auch Trends abgeleitet werden. Dies liefert u. a. wertvolle Erkenntnisse für die operative Steuerung (z. B. Personaleinsatzplanung) und kann dabei helfen, Ineffizienzen und Schwachstellen im Prozess zu finden.

Da dieser Beitrag der erste in einer Reihe von Beiträgen zu diesem Thema ist, konzentriert er sich zunächst auf die Bewegungsklassifikation. Artikel bzgl. der Aktivitätserkennung und der Zeitanalyse befinden sich in Planung.

#### 4 BEWEGUNGSKLASSIFIKATION

Im Rahmen der hier vorgestellten Methode realisiert die Bewegungsklassifikation den Übergang zwischen den Sensordaten und der Aktivitätserkennung. Das Ziel ist es also, die aufgenommenen Sensorwerte im Vorfeld definierten Bewegungsklassen zuzuordnen. Anders gesagt, es müssen Muster in den Sensordaten gefunden werden, die möglichst allen Bewegungen einer Klasse gemeinsam sind und diese klar von anderen Klassen abgrenzen. Damit ist die Bewegungsklassifikation ein klassisches Problem der Mustererkennung. Der typische Aufbau eines Systems zur Mustererkennung ist in Abb. 2 dargestellt.

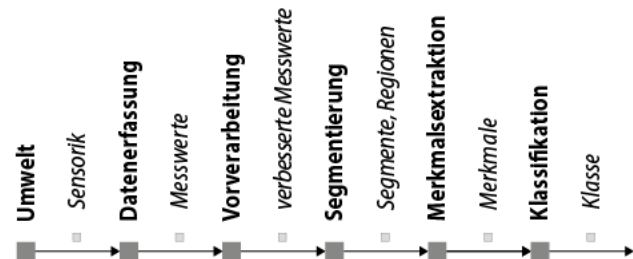


Abbildung 2. Typischer Aufbau eines Mustererkennungssystems (frei nach [Ric11])

Die Sensorwerte werden zu diskreten Zeitpunkten aufgenommen und dementsprechend mit einem Zeitstempel versehen. Die Abtastrate ist abhängig vom Sensor und kann i. d. R. vor der Messung konfiguriert werden. In diesem Beitrag wurde mit Raten von 50 Hz bis 200 Hz gearbeitet. Im Laufe einer Vorverarbeitung werden die Messwerte durch Verfahren der Signalverarbeitung aufbereitet und so weit wie möglich von Störungen befreit. Im Zuge dessen kommen bspw. Tiefpassfilter zum Einsatz [MS12]. Die optionale Segmentierung zerlegt die Daten in sich nicht überlappende Teile, die im weiteren Verlauf gesondert betrachtet werden. Dieser Vorgang ist für Zeitreihendaten i. d. R. schwierig und kommt nicht in jedem Klassifikationssystem zum Einsatz. Deshalb wird im Folgenden mit sich überlappenden Zeitfenstern gearbeitet. Für die eigentliche Klassifikation der Messwerte ist eine Merkmalsextraktion notwendig. Als Merkmal wird dabei eine Datenrepräsentation bezeichnet, welche wichtige Eigenschaften eines Musters beschreibt [Ric11]. Ein Merkmal ist also eine numerische Größe, die von den eigentlichen Mustern in den Sensordaten abstrahiert. Im letzten Schritt der Klassifikation erfolgt die eigentliche Zuordnung der Merkmale zu den Klassen. Für diesen wesentlichen Schritt sind viele verschiedene Verfahren verfügbar, die auch als Klassifikatoren bezeichnet werden.

Der Einsatz von Verfahren der Mustererkennung ist im Bereich der innerbetrieblichen Logistik bereits erprobt worden. So verwenden bspw. Overmeyer et al. Klassifikationsverfahren zur Gestenerkennung im Bereich der Staplersteuerung [DPU<sup>+</sup>14]. Dabei werden Klassifikatoren trainiert, um in einem Bild mit Tiefeninformationen die unterstützten Steuerungsgesten zu erkennen.

Dieses Kapitel ist, in Anlehnung an den typischen Aufbau eines Mustererkennungssystems, wie folgt gegliedert: Zunächst werden die unterstützten Bewegungen für den Prozess der manuellen Kommissionierung identifiziert. Anschließend wird die Sensor- und Merkmalsauswahl für diesen Anwendungsfall beschrieben. Im Zuge dessen werden auch Aspekte der Vorverarbeitung und der Segmentierung thematisiert. Abschließend wird diskutiert, welche Klassifikatoren für diese Aufgabenstellung grundsätzlich infrage kommen und welche für die Erstellung des Prototyps verwendet wurden.

#### 4.1 UNTERSTÜTZTE BEWEGUNGSKLASSEN

Die manuelle Kommissionierung nach dem Prinzip Person-zur-Ware ist auch in Zeiten einer stetig zunehmenden Automatisierung noch immer weit verbreitet. Dies ist laut [Gud12] vor allem auf den geringen technischen Aufwand und die Flexibilität gegenüber schwankenden Durchsatzanforderungen und Sortimentsveränderungen zurückzuführen. In der Ausgestaltung des manuellen Kommissionierprozesses gibt es mehrere Systemtypen mit unterschiedlichen organisatorischen und technischen Ausprägungen. Unterschiede gibt es auch bzgl. der eingesetzten Lade- und Fördermittel. Alle Besonderheiten eines Systems, die sich signifikant auf die Bewegung der Kommissionierer auswirken, müssen bei der Wahl der Bewegungsklassen berücksichtigt werden. Zu diesen Einflussfaktoren zählen technische Funktionselemente, Verfahren zur Kommissioniererführung, Wegstrategien, die Quittierung und die Realisierung einiger Materialflussgrundfunktionen (z. B. die Fortbewegung des Kommissionierers). So kann bspw. die Wahl des Fördermittels direkte Auswirkungen darauf haben, ob sich der Kommissionierer nur gehend oder auch fahrend durch das System, bzw. ein- oder zwei-dimensional durch die Gassen bewegt.

Im Rahmen dieser Arbeit wird die konventionelle, manuelle Kommissionierung betrachtet, bei der sich der Kommissionierer mit einem Kommissionierwagen und Ladehilfsmitteln (z. B. Behälter) zu den statisch bereitgestellten Artikeln bewegt. Dabei kommissioniert er während eines Rundgangs durch das Lager, der an der sogenannten Basis beginnt und endet. An der Basis nimmt er den Auftrag entgegen und stattdessen mit den benötigten Sammelbehältern aus. Die Informationen, die er für das Auffinden der Auftragspositionen benötigt, werden durch eine sogenannte Kommissionierliste zur Verfügung gestellt. Dabei ist es aus Sicht der Bewegungsklassen unerheblich, ob diese Liste digital oder in Papierform bereitgestellt wird, da der Umgang

mit dieser Liste logisch derselben Tätigkeit entspricht und somit derselben Klasse zuzuordnen ist. Nach der Prüfung des nächsten Entnahmeorts begibt sich der Kommissionierer in die entsprechende Lagergasse und sucht das angegebene Regalfach. Anschließend wird der Artikel in der angegebenen Menge entnommen, im Sammelbehälter abgelegt, bei Bedarf die Entnahme quittiert und mit der nächsten Auftragsposition fortgefahren. Nach der Abarbeitung aller Auftragspositionen kehrt der Kommissionierer zurück zur Basis. In Abbildung 3 sind der Ablauf dieses Prozesses und auch die durch die Prozessschritte bedingten Zeitanteile graphisch zusammengefasst. Da sich weder die Aufbau- noch die Ablauf- oder Betriebsorganisation eines manuellen Kommissioniersystems signifikant auf die ausgeführten Bewegungen auswirken, können mit den aus diesem Prozess abgeleiteten Bewegungsklassen sowohl Systeme mit auftragsbezogener als auch solche mit auftragsneutraler Bereitstellung abgebildet werden. Das gleiche gilt auch für ein- und mehrzonige Systeme. Damit werden vier von sieben Kommissioniersystemklassen abgedeckt, die in [VG11] definiert werden.

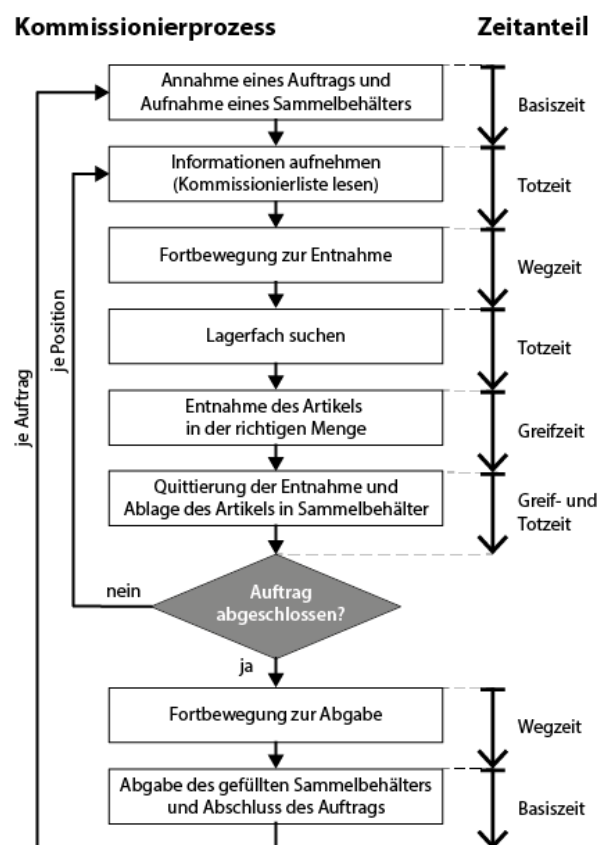


Abbildung 3. Ablauf und Zeitanteile in der manuellen Kommissionierung (frei nach [Wöll14], [GS11, S.82])

Um die benötigten Bewegungsklassen abzuleiten, müssen die Bewegungen, die bei den einzelnen Prozessschritten anfallen, genauer betrachtet werden. Dabei sind Klassen zu identifizieren, die sich aus Sicht der Sensordaten möglichst markant im Zeit- oder Frequenzbereich voneinander unterscheiden.

Zunächst muss jedoch die Granularität der Bewegungsklassen festgelegt werden. Wie bereits zuvor erwähnt, muss die Granularität so gewählt werden, dass die Kommissionierzeitanteile möglichst einzeln quantifiziert werden können. Aus diesem Grund wurden zunächst Bewegungsformen nach MTM-1 betrachtet. MTM-1 ist ein Verfahren, um manuelle Arbeitsabläufe als Folge von Grundbewegungen zu modellieren. Diese Grundbewegungen sind verglichen mit anderen MTM-Verfahren feingliedrig. Beispielsweise wird der Greifvorgang nach MTM-1 in einen Zyklus aus fünf Grundbewegungen des Hand-Arm-Systems unterteilt (vgl. Abb. 4). Der Zyklus beginnt mit dem Hinlangen und dem anschließenden Greifen, bei dem der Artikel unter Kontrolle gebracht wird. Anschließend wird der Artikel zum Ablageort transportiert. Das Fügen spielt bei der Kommissionierung i. d. R. keine große Rolle, da der Artikel meist nicht aufwändig in einen anderen Gegenstand einzustecken oder anzulegen ist. Abschließend wird der Artikel losgelassen und die ausgeübte Kontrolle über diesen wieder aufgehoben.




Abbildung 4. Fünf Grundbewegungen des Finger-, Hand- und Armsystems

Da durch die Greifzeit stets der gesamte Greifvorgang quantifiziert wird, erscheint eine Betrachtung von Bewegungen nach MTM-1 nicht sinnvoll. Das Gleiche gilt für Laufbewegungen. Hier unterscheidet MTM-1 verschiedene Körperbewegungen, wie z. B. Fuß- und Beinbewegungen, Gehen oder den Seitenschritt. Aus Sicht der Kommissionierzeit ist jedoch die Wegzeit von Interesse. Selbst wenn die Wegzeit noch weiter in die Basisweg-, Gassenwechselweg- und Gassenwegzeit aufgegliedert wird, bringt eine Betrachtung einzelner Fuß- und Beinbewegungen keinen weiteren Erkenntnisgewinn. Auf Basis dieser Überlegungen wurden die folgenden Bewegungsklassen definiert:

- Gerades Gehen (*walk straight*, Kürzel W\_S)
- Kurvengang (*walk curve*, Kürzel W\_C)
- Artikelgriff (*pick*, Kürzel PIC)
- Schritt und Griff (*step and grap*, Kürzel SNG)
- Schritt und Ablegen (*step and place*, Kürzel SNP)
- Stehen (*stand*, Kürzel STA)
- Fahren (*drive*, Kürzel DRI)
- Null (*null*, Kürzel NUL)

Dabei erlaubt die Unterscheidung von W\_C und W\_S bei erfolgreicher Klassifikation die Quantifizierung der Zeit für den Gassenweg und den Gassenwechselweg. Der Greifvorgang wird durch die Klasse PIC oder alternativ durch SNG und SNP abgebildet. Unter der NUL-Klasse werden alle Bewegungen zusammengefasst, die keine Relevanz für die Prozessanalyse haben. Für die Informationsaufnahme, die am Anfang jeder Auftragsposition anfällt und zur Totzeit beiträgt, wäre die Definition einer Klasse grundsätzlich sinnvoll. Allerdings können Blickvorgänge und leichte Kopfbewegungen noch nicht berücksichtigt werden, da sie durch die verwendeten Sensoren nicht erfasst werden. Deshalb wird angenommen, dass die Informationsaufnahme meist im Stehen und vereinzelt im Gehen erfolgt. Durch die Definition der Klasse Stehen ist davon auszugehen, dass zumindest langwierige Informationsaufnahmen unter dieser Klasse subsumiert werden und die Vorkommnisse dieser Klasse komplett der Totzeit zugerechnet werden können. Die Handhabung von Hilfsmitteln, das Öffnen bzw. Schließen von Verpackungen oder Blickvorgänge werden im Rahmen dieser Arbeit nicht gesondert betrachtet.

#### 4.2 SENSORAUSWAHL

Im Rahmen von anderen Arbeiten werden zur Erkennung menschlicher Bewegungen und Aktivitäten entweder Kameras, Inertialsensoren oder die Kombination von beiden Datenquellen genutzt [APB<sup>+</sup>13], [ZRF12], [ZX14]. Während Kameras Sequenzen von digitalen Bildern aufzeichnen, auf denen der Proband meist in einer natürlichen Szene bei der Ausführung der Bewegung oder Aktivität abgebildet ist, liefern Inertialsensoren physikalische Informationen wie Beschleunigungen, Drehgeschwindigkeiten oder Änderungen in der magnetischen Flussdichte. In heutigen Anwendungen werden Inertialsensoren häufig als Kombination von Beschleunigungssensor, Gyroskop und Magnetometer eingesetzt, die alle in integrierten Schaltkreisen untergebracht sind. Darüber hinaus gibt es auch verschiedene weitere Sensoren, wie Muskelspannungssensoren, die bspw. für die Analyse des Greifvorgangs genutzt werden könnten [Wöll14]. Um den Kommissionierer mit möglichst wenig zusätzlichen technischen Geräten und Kleidungsstücken auszustatten, wird zunächst nur mit Sensoren gearbeitet, die in mobilen Endgeräten verfügbar sind. Da mittlerweile verschiedene industrietaugliche

Smartphones angeboten werden, die sowohl über Inertialsensorik als auch über hochauflösende Kamerachips verfügen, können beide Sensoren für die Bewegungsklassifikation eingesetzt werden.

Obwohl Inertialsensoren im Gegensatz zu Kameras über ein vergleichsweise einfaches Sensorsignal ( $x(t)$ ,  $y(t)$  und  $z(t)$ ) verfügen, gibt es doch verschiedene Herausforderungen und sensorspezifische Probleme, die berücksichtigt werden müssen. So misst der Beschleunigungssensor neben den Bewegungsbeschleunigungen auch die Erdbeschleunigung (Gravitation) [MS12, S.108]. Um die lineare Beschleunigung zu messen, muss daher die Auswirkung der Gravitation aus dem Sensorsignal herausgerechnet werden. Dazu kann die Gravitation mithilfe eines Tiefpassfilters bestimmt und von dem Sensorsignal abgezogen werden. Aber auch die anderen Inertialsensoren haben spezifische Schwächen. So unterliegt das Gyroskop einem sogenannten Sensordrift, und der Magnetfeldsensor kann durch die Gegenwart von Metall gestört werden. Entsprechende Gegenmaßnahmen zum Umgang mit solchen Problemen können in den Prozess der Vorverarbeitung integriert werden.

### 4.3 MERKMALE UND ZEITFENSTER

Den Merkmalen kommt in der Mustererkennung eine wichtige Rolle zu. Sie repräsentieren Daten, welche die Eigenschaften eines Musters numerisch beschreiben, und von den eigentlichen Sensorwerten abstrahieren. Sie verdichten das Ursprungssignal also i. d. R. zu einem charakteristischen Wert.

Im Bereich der Bewegungsklassifikation und Aktivitätserkennung kommen sehr viele verschiedene Merkmale und auch Berechnungsverfahren in Frage [FDF<sup>+</sup>10]. Die Auswahl geeigneter Merkmale ist ein aufwändiger empirischer Vorgang, der für den Anwendungsfall der manuellen Kommissionierung im Rahmen zukünftiger Arbeiten intensiver betrachtet werden soll. In einem ersten Schritt wurden durch eine Literaturrecherche häufig verwendete Merkmale aus anderen Anwendungen ermittelt und verwendet [FDF<sup>+</sup>10], [BAK<sup>+</sup>14], [KNM<sup>+</sup>06]. Momentan werden die folgenden Merkmale berücksichtigt: Minimum, Maximum, Arithmetisches Mittel, Standardabweichung sowie der Betrag der Signalvektoren. Aktuell werden für die neun Sensorwerte insgesamt 45 Merkmale berechnet und zu einem Merkmalsvektor zusammengefasst.

Beim Umgang mit Daten von Inertialsensoren werden die Merkmale häufig nicht für einzelne Sensorwerte, sondern für gleitende Zeitfenster bestimmt [Sii15]. Dabei werden die Signale in gleich große Sequenzen zerschnitten, die entweder direkt aufeinanderfolgen oder sich auch überlappen können [OSB04]. Dies unterscheidet Zeitfenster von Segmenten. In der Bewegungsklassifikation wird häufig mit Zeitfenstergrößen zwischen einer und fünf Sekunden und einer Überlappung von 50 Prozent gearbeitet. Durch diese Fenstergröße soll sichergestellt werden, dass die

Klassifikation nicht zu lange benötigt, um auf neue Bewegungen zu reagieren [HNT13]. Anstatt für jeden Messpunkt des Signals die zugehörige Klasse zu bestimmen, werden die Klassen pro Fenster bestimmt. Dieses Vorgehen wird auch *Sliding-Window-Verfahren* genannt (vgl. Abb. 5). Da verschiedene Sensorabstraten eingesetzt werden mussten, konnten die Zeitfenster nicht wie üblich mit einer parametrierbaren Überlappung werteweise weitergeschoben werden. Stattdessen werden die Zeitfenster in festen Zeitschritten weitergeschoben, wobei die Schrittweite im Vorfeld festgelegt wird.




Abbildung 5. Beispiel des Sliding-Window-Verfahrens mit einer Fenstergröße von 2 s und einer Schrittweite von 0,5 s [Sii15]

### 4.4 KLASSIFIKATOREN

Die Aufgabe von Klassifikatoren ist es, den Sensorwerten eine der verfügbaren Klassen zuzuordnen. Ähnlich wie bei den Merkmalen stehen auch bei den Klassifikatoren viele verschiedene Verfahren zur Auswahl. Um die Stärken und Schwächen verschiedener Klassifikatoren zu kombinieren und die Erkennungsrate zu erhöhen, können mehrere Klassifikatoren parallel eingesetzt werden. In diesem Zusammenhang wird auch von Klassifikator-Ensembles gesprochen. Da jeder Klassifikator eine komplette Zuordnung vornimmt, muss das Gesamtergebnis durch die Aggregation der Einzelergebnisse bestimmt werden. Dies kann bspw. durch einen Mehrheitsentscheid realisiert werden.

Eine Literaturrecherche ergab, dass die folgenden Klassifikatoren bereits zur Erkennung von Bewegungsmustern eingesetzt werden: *k-nearest-Neighbour*, *Bayes*, *Random Forest*, *Support Vector Machines*, *Adaptive Boost* und neuronale Netze. Zum Zweck der Komplexitätsreduzierung werden zunächst die folgenden drei Standardklassifikatoren für die manuelle Kommissionierung erprobt:

- *Bayes*-Klassifikator
- *Random-Forest*-Klassifikator
- *Support Vector Machines* (SVMs)





stimmt und dokumentiert. Im Anschluss werden sie zusammen mit den Sensordaten in MATLAB geladen und zur Erstellung der annotierten Sensorwerte genutzt. Im nächsten Schritt werden die annotierten Trainingsdaten in den Modellerzeugungsbaustein geladen. Dieses Programm berechnet zunächst die überlappenden Zeitfenster, extrahiert für jedes Fenster die ausgewählten Merkmale und parametrisiert die drei Klassifizierer. Jedes Fenster wird mit der Klasse annotiert, die innerhalb des Fensters am häufigsten vorkommt. Anschließend werden die Klassifizierer trainiert und die dabei entstehenden Modelle für die Betriebsphase persistent gespeichert. Zusätzlich werden Plots der aufgenommenen und annotierten Daten erstellt, damit eine einfache optische Prüfung der Trainingsdaten und der manuell erstellten Annotationen durchgeführt werden kann.

## 5.2 DATENAUFNAHME

Zum Zweck der Datenaufnahme wird ein Smartphone mit integrierter *Inertial Measurement Unit* (IMU) genutzt. Um die Messwerte in der Nähe des Schwerpunkts zu bestimmen, wird ein Brustgurt mit einer Halterung für das Mobiltelefon verwendet. Zukünftig soll eine am Handgelenk getragene IMU zum Einsatz kommen, welche ermöglicht, die Greifbewegungen während der Kommissionierung besser zu erfassen. Die Daten der IMU sollen dabei per Bluetooth an das Telefon übertragen und dort zusammen mit den Messungswerten der internen IMU in regelmäßigen Abständen auf die SD-Karte geschrieben werden. Abbildung 7 zeigt den grundsätzlichen Aufbau der Messausrüstung.

Das Herzstück der Messausrüstung bildet eine dafür entwickelte App, welche alle Sensorereignisse über das Betriebssystem empfängt und strukturiert abspeichert. Zur einfacheren Bedienung der App und vor allem, um das Smartphone nicht wiederholt aus der Halterung nehmen zu müssen, werden NFC-Transponder (*Near Field Communication*) zur Steuerung der Aufnahmen verwendet. Zu diesem Zweck werden alle für die Messungen benötigten Parameter, wie die zu verwendenden Sensoren, die Abtastrate oder optional auch die aufzunehmende Tätigkeit, auf dem Transponder gespeichert. Nach dem Scannen erfolgt die Rückmeldung durch ein akustisches Signal und den Blitz der Handykamera. Das ausgesendete Blitzsignal zeigt in der Videoaufnahme an, wann der Messprozess gestartet oder beendet wird. Dies hilft dabei, die Sensor- und die Videodaten im Laufe der manuellen Bewegungsanalyse zeitlich zu synchronisieren.

## 5.3 BETRIEB

Während des Betriebs werden die unklassifizierte Sensordaten und die während der Trainingsphase erstellten Modelle geladen. Ein Programm berechnet analog zum Training zuerst die überlappenden Zeitfenster und extrahiert die Merkmale aus den Signalen. Anschließend werden die drei Klassifizierer erzeugt und mit den Modellen initialisiert. Danach erfolgt die eigentliche Klassifikation. Dabei

wird für jeden Sensorwert automatisch eine Klasse bestimmt. Die klassifizierte Daten werden dann zusammen mit Zeitreihenplots abgespeichert und stehen für die weitere Verarbeitung zur Verfügung. Durch eine Analyse der Zeitreihen wäre es möglich, erste Kommissionierzeitanteile für den betrachteten Prozess zu quantifizieren.



Abbildung 7. Messausrüstung

## 6 EVALUIERUNG

Die Erprobung der Bewegungsklassifikation soll Erkenntnisse über die Trennschärfe der Klassen und die Erkennungsrate der Klassifikatoren ermitteln. Damit liefert sie wertvolle Anhaltspunkte für die Methodenoptimierung.

Im Rahmen der Evaluierung wurden in einem manuellen Kommissioniersystem mit drei verschiedenen Versuchspersonen jeweils mehrere Datensätze aufgenommen. In diesem Versuchssystem wurde kein Kommissionierleit-system eingesetzt und die Entnahme musste nicht quittiert werden. Als Fördermittel wurde ein Kommissionierwagen mit einem Behälter für die Auftragsablage verwendet. Die Lagerung erfolgte ohne zusätzliche Umverpackung in Fachbodenregalen. Im Zuge einer Messung musste von jedem Probanden ein Auftrag mit sechs Positionen bearbeitet werden. Die zu kommissionierenden Artikel lagerten auf unterschiedlichen Greifhöhen und mussten innerhalb der Gasse sowohl aus dem linken als auch aus dem rechten Regal gepickt werden.

Jede Messung dauerte ca. 2,5 Minuten. Währenddessen wurden jeweils die X-, Y- und Z-Werte des Beschleunigungssensors, des Gyroskops und des Magnetfeldsensors erfasst und zusammen mit einem Zeitstempel persistent gespeichert. Dabei wurde mit der höchsten von den Sensoren bzw. dem Betriebssystem des Smartphones unterstützten Abtastrate gearbeitet. Aufgrund einer Einschränkung des Betriebssystems konnte keine fixe Abtastrate eingestellt werden, so dass die Rate im Laufe der Messungen leicht schwankte. Die erzielten Abtastraten und die durchschnittliche Anzahl der aufgenommenen Werte können Tabelle 1 entnommen werden.




Abbildung 8. Alle aufgenommenen Werte eines Messdurchlaufs inkl. des Start-/Stopsignals ohne Annotationen

Tabelle 1. Aufgenommene Sensorwerte

Sensorwert	Ø-Abtastrate in [Hz]	Ø-Messungen pro Achse
Beschleunigung	99,74 Hz	14.912
Drehgeschwindigkeit	199,52 Hz	29.831
Mag. Flussdichte	47,89 Hz	7.159

Zudem wurde mit einer Kamera jede Messung auf Video festgehalten. Um die Synchronisierung der Videoaufnahmen und Daten zu erleichtern, wurde ein markantes Start-/Stoppsignal verwendet, das sich sowohl in den Videos als auch in den Sensorwerten wiederfindet. Dazu wurde vor Beginn und am Ende jeder Messung das Smartphone samt Halterung dreimal um seine X-Achse gedreht. Eine graphische Darstellung eines Messdatensatzes inkl. Start- und Stoppsignal ist in Abbildung 8 zu sehen.

Nach Abschluss der Messungen wurden die Daten zur weiteren Auswertung auf einen PC übertragen. Bei der Auswertung wurden zunächst das Video und die Messdaten synchronisiert, indem der Versatz zwischen beiden Aufzeichnungen bestimmt wurde. Anschließend konnten

aus dem Video die durchlaufenen Bewegungsklassen sowie deren Start- und Endzeitpunkte ermittelt werden. Diese Daten wurden zum Annotieren der Sensorwerte genutzt.




Abbildung 9. Aufgenommene Beschleunigungswerte mit vertikal eingezeichneten Annotationen

Die annotierten Sensordaten (vgl. Abb. 9) dienen als Grundlage für eine dreifache Kreuzvalidierung, die Aufschluss über die Zuverlässigkeit der Klassifikatoren geben sollte. Im Zuge dessen wurden zwei der drei Datensätze für das Training und der dritte für den Test der Klassifikation verwendet. Dabei wurden für den Testdatensatz die Klassen durch das Klassifikatormodell bestimmt und anschließend mit den im Vorfeld annotierten Klassen verglichen. Durch den Vergleich von Vorhersage und Wirklichkeit

ergab sich die Erkennungsrate für einen Validierungslauf. Im Rahmen der Kreuzvalidierung wird jeder Datensatz einmal als Testdatensatz verwendet. Die Gesamterkennungsrate eines Klassifikators resultiert aus dem Durchschnitt der Erkennungsraten aus den drei Validierungsläufen (vgl. Tab. 2 und Tab. 3).

Tabelle 2. Erkennungsraten bei einer Fenstergröße von 2,5 Sekunden und einer Schrittweite von einer Sekunde

Validierungslauf	SVM	Bayes	R.Forest
1 (P1,P2/P3)	56,13%	80,00%	71,61%
2 (P1,P3/P2)	47,37%	84,87%	82,24%
3 (P2,P3/P1)	52,52%	71,94%	69,06%
Durchschnitt	52,01%	78,94%	74,30%
Standardabweichung	4,40%	6,53%	6,99%

Tabelle 3. Erkennungsraten bei einer Fenstergröße von einer Sekunde und einer Schrittweite von 0,036 Sekunden

Validierungslauf	SVM	Bayes	R.Forest
1 (P1,P2/P3)	28,82%	76,88%	78,00%
2 (P1,P3/P2)	23,44%	85,41%	74,66%
3 (P2,P3/P1)	27,86%	60,51%	67,06%
Durchschnitt	26,71%	74,27%	73,24%
Standardabweichung	2,87%	12,65%	5,61%

Die besten Resultate lieferte der *Bayes*-Klassifikator, gefolgt von dem *Random-Forest*-Klassifikator. Der *SVM*-Klassifikator dagegen lieferte unerwartet schlechte Ergebnisse, obwohl dieses Verfahren in verschiedenen Arbeiten zum Thema Bewegungsklassifikation Verwendung findet [MHB<sup>+</sup>14], [SH15], [VHD12]. Bei verschiedenen Validierungsläufen mit unterschiedlichen Fenstergrößen und Schrittweiten zeigte sich, dass beim *SVM*-Klassifikator die durchschnittliche Erkennungsrate mit zunehmender Schrittweite steigt. Da eine Erhöhung der Schrittrate dazu führt, dass die Überlappung zweier aufeinander folgender Fenster reduziert wird, liegt der Schluss nahe, dass sich bei diesem Verfahren eine Überlappung unter den gegebenen Umständen negativ auf die Erkennungsrate auswirkt. Beim *Bayes*-Klassifikator dagegen wirkte sich eine Erhöhung der Schrittweite kaum auf die Erkennungsrate aus. Dafür zeigte eine Erhöhung der Fenstergröße bei diesem Klassifikator positive Effekte. Auf die Zuverlässigkeit des *Random-Forest*-Klassifikators wirkten sich die Fenstergröße und die Schrittweite nicht merklich aus.

Eine Analyse der Konfusionsmatrizen der eingesetzten Verfahren zeigte, dass sowohl *Bayes* als auch *Random-Forest* gute Ergebnisse für die Klassifizierung des Greifvorgangs erzielten (95,78 bzw. 90,85 Prozent). Beide Verfahren konnten jedoch nicht den Kurvengang vom Greifvorgang unterscheiden (0 Prozent in beiden Fällen).

## 7 ZUSAMMENFASSUNG UND AUSBLICK

In diesem Beitrag wurde eine neue Methode zur Analyse des manuellen Kommissionierprozesses vorgestellt, mit der u. a. die Kommissionierzeitanteile automatisch erfasst werden können. Diese Methode basiert auf einer sensorgestützten Bewegungsklassifikation und einer automatischen Aktivitätserkennung und nutzt dazu Verfahren des überwachten maschinellen Lernens. Als Teil einer Reihe von Veröffentlichungen konzentriert sich dieser Beitrag auf die Bewegungsklassifikation. Weitere Beiträge zur Datenaufnahme und zur Aktivitätserkennung sind in Vorbereitung. Durch die Analyse des Kommissionierprozesses konnten zunächst relevante Bewegungsklassen identifiziert werden. Im Anschluss wurde der Auswahlprozess der Sensoren, Merkmale und Klassifikatoren beschrieben. Dabei wurde insbesondere der Einsatz des leicht abgewandelten *Sliding-Window*-Verfahrens näher betrachtet. Dies lieferte die Grundlage für die methodische Ausgestaltung der Bewegungsklassifikation. Abschließend wurde die Bewegungsklassifikation prototypisch umgesetzt und mit Testdaten evaluiert. Dabei konnten Erkennungsraten von bis zu 78,94 Prozent erzielt werden. Dieser Wert ist im Vergleich zu anderen Arbeiten auf dem Gebiet vergleichsweise gering und bietet Potenzial für Optimierungen.

In zukünftigen Forschungsarbeiten wird die vorgeschlagene Methode weiterentwickelt und verfeinert, mit dem Ziel, die Erkennungsraten der Klassifikation auf über 90 Prozent zu steigern. Dazu soll zum einen die Vorverarbeitung verbessert werden, z. B. durch den Einsatz von Filtern und einer Kontextbestimmung im Rahmen der Messungen. Diese Modifikationen sollen dabei helfen, die Daten im Vorfeld mit dem Ort zu kennzeichnen, an dem sie erhoben wurden. Zum anderen sollen die Merkmals- und Klassifikatorauswahl erweitert und systematisiert werden, z. B. durch Methoden wie die *Sequential Forward Selection* [DK82]. Zudem wird die Hinzunahme einer weiteren IMU am Handgelenk evaluiert, um die Unterscheidung von Kurvengang und Greifvorgang zu verbessern.

## LITERATURVERZEICHNIS

- [AB14] Alam, Muhammad Mahtab; Ben Hamida, Elyes: *Surveying wearable human assistive technology for life and safety critical applications: standards, challenges and opportunities*. In: *Sensors (Basel, Switzerland)* 14 (2014), Nr. 5, S. 9153–9209. – DOI 10.3390/s140509153
- [APB<sup>+</sup>13] Andersson, M.; Patino, L.; Burghouts, G. J.; Flizikowski, A.; Evans, M.; Gustafsson, D.; Petersson, H.; Schutte, K.; Ferryman, J.: *Activity recognition and localization on a truck parking lot*. In: *Advanced Video and Signal Based Surveillance (AVSS), 2013 10th IEEE International Conference on*, 2013, S. 263–269

- [AGO<sup>+</sup>12] Anguita, Davide; Ghio, Alessandro; Oneto, Luca; Parra, Xavier; Reyes-Ortiz, Jorge L.: Human Activity Recognition on Smartphones Using a Multiclass Hardware-Friendly Support Vector Machine, Bd. 7657. In: HUTCHISON, David; KANADE, Takeo; KITTLER, Josef; KLEINBERG, Jon M.; MATTERN, Friedemann; MITCHELL, John C.; NAOR, Moni; NIERSTRASZ, Oscar; PANDU RANGAN, C.; STEFFEN, Bernhard; SUDAN, Madhu; TERZOPOULOS, Demetri; TYGAR, Doug; VARDI, Moshe Y.; WEIKUM, Gerhard; BRAVO, José; HERVÁS, Ramón; RODRÍGUEZ, Marcela (Hrsg.): *Ambient Assisted Living and Home Care*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2012 (Lecture Notes in Computer Science). – ISBN 978-3-642-35394-9, S. 216–223
- [DK82] Devijver, Pierre A.; Kittler, Josef: *Pattern recognition: A statistical approach*. Englewood Cliffs, NJ: Prentice-Hall, 1982. – ISBN 0-13-654236-0
- [DXB<sup>+</sup>11] Dobkin, Bruce H.; Xu, Xiaoyu; Batalin, Maxim; Thomas, Seth; Kaiser, William: *Reliability and validity of bilateral ankle accelerometer algorithms for activity recognition and walking speed after stroke*. In: *Stroke; a journal of cerebral circulation* 42 (2011), Nr. 8, S. 2246–2250. – DOI 10.1161/STROKEAHA.110.611095
- [AGR<sup>+</sup>02] Auvinet, B.; Gloria, E.; Renault, G.; Barrey, E.: *Runner's stride analysis: Comparison of kinematic and kinetic analyses under field conditions*. In: *Science & Sports* 17 (2002), Nr. 2, S. 92–94. – DOI 10.1016/S0765-1597(02)00122-3
- [DPU<sup>+</sup>14] Dohrmann, Lars; Podszus, Florian; Ullmann, Georg; Overmeyer, Ludger: *Mensch-Maschine-Interaktion für Fahrerlose Transportfahrzeuge: Methode zur Beauftragung von interaktiven Transportsystemen*. In: *Industrie Management* o. Jg. (2014), Nr. 6, S. 21–24.
- [BFS<sup>+</sup>08] Bächlin, M.; Forster, K.; Schumm, J.; Breu, D.; Germann, J.; Troster, G.: An automatic parameter extraction method for the 7<sup>Å</sup>—50m Stroke Efficiency Test, Bd. 1. In: *Proceedings of IPCA*, 2008, S. 442–447
- [FBG<sup>+</sup>13] Fernández-Llatas, Carlos; Benedi, José-Miguel; García-Gómez, Juan M.; Traver, Vicente: *Process mining for individualized behavior modeling using wireless tracking in nursing homes*. In: *Sensors (Basel, Switzerland)* 13 (2013), Nr. 11, S. 15434–15451.
- [BKL05] Beetz, M.; Kirchlechner, B.; Lames, M.: *Computerized real-time analysis of football games*. In: *Pervasive Computing, IEEE* 4 (2005), Nr. 3, S. 33–39.
- [FDF<sup>+</sup>10] Figo, Davide; Diniz, Pedro C.; Ferreira, Diogo R.; Cardoso, João M: *Preprocessing techniques for context recognition from accelerometer data*. In: *Personal and Ubiquitous Computing* 14 (2010), Nr. 7, S. 645–662.
- [BAK<sup>+</sup>14] Bersch, Sebastian D.; Azzi, Djamel; Khunsainov, Rinat; Achumba, Ifeyinwa E.; Ries, Jana: *Sensor data acquisition and processing parameters for human activity classification*. In: *Sensors (Basel, Switzerland)* 14 (2014), Nr. 3, S. 4239–4270. – DOI 10.3390/s140304239
- [Gar15] Garmin: *Forerunner920xt* <https://forerunner920.garmin.com/de-DE> – Überprüfungsdatum 2015-09-01
- [BSK<sup>+</sup>07] Bidargaddi, N.; Sarela, A.; Klingbeil, L.; Karunanithi, M.: Detecting walking activity in cardiac rehabilitation by using accelerometer. In: IEEE (Hrsg.): *Intelligent Sensors, Sensor Networks and Information, 2007.*, 2007. – ISBN 978-1-4244-1501-4, S. 555–560
- [Gud05] Gudehus, Timm: *Logistik: Grundlagen, Strategien, Anwendungen*. 3., neu bearb. Aufl. Berlin [u.a.]: Springer, 2005 (SpringerLink: Springer e-Books). – ISBN 978-3-540-24113-3
- [Bis06] Bishop, Christopher M.: *Pattern recognition and machine learning*. New York, NY: Springer, 2006 (Information science and statistics). – ISBN 978-0387-31073-2
- [Gud12] Gudehus, Timm: *Logistik 2: Netzwerke, Systeme und Lieferketten*. 4., aktualisierte und erw. Aufl., Studienausg. Berlin [u.a.]: Springer, 2012 (VDI-Buch). – ISBN 364229376X
- [BHR12] Bravo, José; Hervás, Ramón; Rodríguez, Marcela: *Ambient Assisted Living and Home Care: 4th International Workshop*, IWAAL 2012, Vitoria-Gasteiz, Spain, December 3-5, 2012. *Proceedings*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012 (Lecture Notes in Computer Science). – ISBN 978-3-642-35394-9
- [GS11] Günthner, W. A.; Steghafner, Andreas: *Kommissioniersystem-Planung mit VR: KomPlanVR ; Forschungsbericht ;*. München: Technische Univ, 2011

- [GDR<sup>+</sup>14] Günthner, Willibald A.; Deuse, Jochen; Rammelmeier, Tobias; Weisner, Kirsten: *Forschungsbericht Entwicklung und technische Integration einer Bewertungsmethodik zur Ermittlung von Mitarbeiterbelastungen in Kommissioniersystemen (ErgoKom)*. Garching: Lehrstuhl für Fördertechnik, Materialfluss, Logistik, Techn. Univ. München, 2014. – ISBN 978-3-941702-41-7
- [HMK<sup>+</sup>14] Habib, Mohammad Ashfaq; Mohktar, Mas S.; Kamaruzzaman, Shahrul Bahyah; Lim, Kheng Seang; Pin, Tan Maw; Ibrahim, Fatimah: *Smartphone-based solutions for fall detection and prevention: challenges and open issues*. In: *Sensors (Basel, Switzerland)* 14 (2014), Nr. 4, S. 7181–7208. – DOI 10.3390/s140407181
- [HLM<sup>+</sup>15] Hardegger, Michael; Ledergerber, Benjamin; Mutter, Severin; Vogt, Christian; Seiter, Julia; Calatroni, Alberto; Tröster, Gerhard: *Sensor Technology for Ice Hockey and Skating*. In: *Proceedings of the 12th Annual Body Sensor Networks Conference* : IEEE, 2015
- [Har11] Hartmann, Bastian: *Human worker activity recognition in industrial environments*. KIT, Diss.--Karlsruhe, 2011. Karlsruhe: KIT Scientific Publishing, 2011. – ISBN 9783866446434
- [HNT13] Hemminki, Samuli; Nurmi, Petteri; Tarkoma, Sasu: *Accelerometer-based transportation mode detection on smartphones*. In: *SenSys*, 2013
- [HZY11] Hu, Derek Hao; Zheng, Vincent Wenchen; Yang, Qiang: *Cross-domain activity recognition via transfer learning*. In: *Pervasive and Mobile Computing* 7 (2011), Nr. 3, S. 344–358.
- [HVB14]: *Industrie 4.0 in Produktion, Automatisierung und Logistik: Anwendung, Technologien, Migration*. Wiesbaden: Springer Vieweg, 2014 (SpringerLink). – ISBN 9783658046811
- [JJK14] Jeong, Seol Young; Jo, Hyeong Gon; Kang, Soon Ju: *Fully distributed monitoring architecture supporting multiple trackees and trackers in indoor mobile asset management application*. In: *Sensors (Basel, Switzerland)* 14 (2014), Nr. 3, S. 5702–5724.
- [KNM<sup>+</sup>06] Karantonis, D. M.; Narayanan, M. R.; Mathie, M.; Lovell, N. H.; Celler, B. G.: *Implementation of a Real-Time Human Movement Classifier Using a Triaxial Accelerometer for Ambulatory Monitoring*. In: *IEEE Transactions on Information Technology in Biomedicine* 10 (2006), Nr. 1, S. 156–167. – DOI 10.1109/TITB.2005.856864
- [KSS<sup>+</sup>10] Kregel, M.; Schmauder, M.; Schmidt, Thorsten; Turek, K.: *Beschreibung der Dynamik manueller Operationen in logistischen Systemen: Schlussbericht*. Dresden, 2010
- [KKB14] Kwon, Yongjin; Kang, Kyuchang; Bae, Changseok: *Unsupervised learning for human activity recognition using smartphone sensors*. In: *Expert Systems with Applications* 41 (2014), Nr. 14, S. 6067–6074. – DOI 10.1016/j.eswa.2014.04.037
- [LC11] Lee, Young Seol; Cho, Sung Bae: *Activity recognition using hierarchical hidden markov models on a smartphone with 3D accelerometer*, 6678 LNAI. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2011. – ISBN 9783642212185, S. 460–467
- [LL09] Li, Mo; Liu, Yunhao: *Underground coal mine monitoring with wireless sensor networks*. In: *ACM Transactions on Sensor Networks* 5 (2009), Nr. 2, S. 1–29. – DOI 10.1145/1498915.1498916
- [LKA<sup>+</sup>06] Linz, T.; Kallmayer, C.; Aschenbrenner, R.; Reichl, H.: *Fully Integrated EKG Shirt based on Embroidered Electrical Interconnections with Conductive Yarn and Miniaturized Flexible Electronics*. In: *International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06)*, 2006, S. 23–26
- [LYA09] Long, Xi; Yin, Bin; Aarts, Ronald M.: *Single-accelerometer-based daily physical activity classification*. In: *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference 2009* (2009), S. 6107–6110. – DOI 10.1109/IEMBS.2009.5334925
- [MHB<sup>+</sup>14] Mandal, I.; Happy, S. L.; Behera, D. P.; Routray, A.: *A framework for human activity recognition based on accelerometer data*. In: *Confluence The Next Generation Information Technology Summit (Confluence), 2014 5th International Conference -*, 2014. – ISBN 978-1-4799-4237-4, S. 600–603

- [MHZ<sup>+</sup>12] Mazilu, Sinziana; Hardegger, Michael; Zhu, Zack; Roggen, Daniel; Tröster, Gerhard; Plotnik, Meir; Hausdorff, Jeffrey M.: Online Detection of Freezing of Gait with Smartphones and Machine Learning Techniques. In: *6th IEEE International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth)* : IEEE, 2012. – ISBN 978-1-4673-1483-1, S. 123–130
- [MS05] Michahelles, F.; Schiele, B.: *Sensing and monitoring professional skiers*. In: *Pervasive Computing, IEEE* 4 (2005), Nr. 3, S. 40–45. – DOI 10.1109/MPRV.2005.66
- [MS12] Milete, Greg; Stroud, Adam: *Professional Android sensor programming*. Indianapolis: John Wiley & Sons, 2012 (Wrox programmer to programmer). – ISBN 978-1-118-18348-9
- [OSB04] Oppenheim, Alan V.; Schafer, Ronald W.; Buck, John R.: *Zeitdiskrete Signalverarbeitung*. München [u.a.]: Pearson Studium, 2004. – ISBN 3-8273-7077-9
- [PAH<sup>+</sup>15] Pancardo, Pablo; Acosta, Francisco; Hernández-Nolasco, José; Wister, Miguel; López-de-Ipiña, Diego: *Real-Time Personalized Monitoring to Estimate Occupational Heat Stress in Ambient Assisted Working*. In: *Sensors* 15 (2015), Nr. 7, S. 16956–16980. – DOI 10.3390/s150716956
- [PEH<sup>+</sup>14] Pancardo, Pablo; Escalante, Francisco D; Hernández-Nolasco, José Adán; Wister, Miguel A.; López-de-Ipiña, Diego: A sensor-based method for occupational heat stress estimation, Bd. 8867. In: *Lecture Notes in Computer Science (including sub-series Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2014. – ISBN 9783319131016, S. 251–258
- [PEK<sup>+</sup>06] Parkka, J.; Ermes, M.; Korpipaa, P.; Mantyjarvi, J.; Peltola, J.; Korhonen, I.: *Activity classification using realistic data from wearable sensors*. In: *Information Technology in Biomedicine, IEEE Transactions on* 10 (2006), Nr. 1, S. 119–128.
- [Pol15] Polar: *Polar V800.: Die Wahl der ambitioniertesten Sportler*. <http://www.polarv800.com/de/v800.php> – Überprüfungsdatum 2015-09-01
- [Ric11] Richarz, Jan: *Videobasierte Gestenerkennung in einer intelligenten Umgebung*, 2011
- [RC11] Ryoo, Boong Yeol; Chung, Hyun Chul: *Wireless/mobile sensors for monitoring worker's health and safety in construction*. In: *Proceedings of the 28th International Symposium on Automation and Robotics in Construction, ISARC 2011* (2011), S. 572–573.
- [Sab06] Sabatini, Angelo M.: *Quaternion-based extended Kalman filter for determining orientation by inertial and magnetic sensing*. In: *IEEE Transactions on Biomedical Engineering* 53 (2006), Nr. 7, S. 1346–1356.
- [Sad07] Sadowsky, Volker: *Beitrag zur analytischen Leistungsermittlung von Kommissioniersystemen*. Dortmund: Verl. Praxiswissen, 2007 (Logistik für die Praxis). – ISBN 389957057X
- [SH15] Shafique, Muhammad Awais; Hato, Eiji: *Use of acceleration data for transportation mode prediction*. In: *Transportation* 42 (2015), Nr. 1, S. 163–188.
- [Sie13] Siepenkort, André: *Methode zur Messung und Bewertung der individuellen Kommissionierleistung in "Person-zur-Ware"-Systemen*. Univ., Diss.–Stuttgart, 2012. Stuttgart: Institut für Fördertechnik und Logistik, 2013 (Berichte aus dem Institut für Fördertechnik und Logistik)
- [Sii15] Siirtola, Pekka: *Recognizing human activities based on wearable inertial measurements: methods and applications*. Oulu, 2015. – ISBN 978-952-62-0768-1
- [SSW14] Stinson, Matthew Russell; Sommer, Tobias; Wehking, Karl-Heinz: *Bewertung und Optimierung der Effizienz manueller Tätigkeiten in der Kommissionierung (EfKom): Abschlussbericht*. Stuttgart: Univ. Inst. für Fördertechnik und Logistik (IFT), 2014
- [TIH<sup>+</sup>07] Tapia, Emmanuel Munguia; Intille, Stephen S.; Haskell, William; Larson, Kent; Wright, Julie; King, Abby; Friedman, Robert: *Real-Time Recognition of Physical Activities and Their Intensities Using Wireless Accelerometers and a Heart Rate Monitor*. In: *11th IEEE International Symposium on Wearable Computers*, 2007, S. 1–4
- [tSB11] ten Hompel, Michael; Sadowsky, Volker; Beck, Maria: *Kommissionierung: Materialflusssysteme 2 - Planung und Berechnung der Kommissionierung in der Logistik*. Berlin [u.a.]: Springer, 2011 (VDI-Buch). – ISBN 978-3-540-29622-5

- [TTM06] Toney, A. P.; Thomas, B. H.; Marais, W.: Managing Smart Garments. In: *Wearable Computers, 2006 10th IEEE International Symposium on*, 2006, S. 91–94
- [TMA<sup>+</sup>12] Trabelsi, D.; Mohammed, S.; Amirat, Y.; Oukhellou, L.: Activity recognition using body mounted sensors: An unsupervised learning based approach. In: *Neural Networks (IJCNN), The 2012 International Joint Conference on*, 2012. – ISBN 978-1-4673-1488-6, S. 1–7
- [TMC<sup>+</sup>13] Trabelsi, D.; Mohammed, S.; Chamroukhi, F.; Oukhellou, L.; Amirat, Y.: *An Unsupervised Approach for Automatic Activity Recognition Based on Hidden Markov Model Regression*. In: *Automation Science and Engineering, IEEE Transactions on* 10 (2013), Nr. 3, S. 829–835.
- [VG11] Venn, Eric; Geißen, Tim: *Kommissionieren mit System: Mit acht Bausteinen erfolgreich planen*. In: *Hebezeuge Fördermittel* 51 (2011), Nr. 6, S. 338–342.
- [VHD12] Vo, Quang Viet; Hoang, Minh Thang; Deok, Jai Choi: Balancing Precision and Battery Drain in Activity Recognition on Mobile Phone. In: *Parallel and Distributed Systems (ICPADS), 2012 IEEE 18th International Conference on*, 2012. – ISBN 978-1-4673-4565-1, S. 712–713
- [WCM10] Wang, Shuangquan; Chen, Canfeng; Ma, Jian: Accelerometer based transportation mode recognition on mobile phones. In: *APWCS 2010 - 2010 Asia-Pacific Conference on Wearable Computing Systems*, 2010. – ISBN 9780769540030, S. 44–46
- [Wöl14] Wölfle, Michael: *Kontextsensitive Arbeitsassistenzsysteme zur Informationsbereitstellung in der Intralogistik*. Techn. Univ., Diss.--München, 2014. München: fml - Lehrstuhl für Fördertechnik Materialfluss Logistik TUM, 2014. – ISBN 9783941702523
- [YCI<sup>+</sup>09] Yu, chen ho; Ching, hu lu; I, han chen; Shih, Shinh Huang; Ching, Yao Wang; Li, chen fu: Active-learning assisted self-reconfigurable activity recognition in a dynamic environment. In: *Robotics and Automation, 2009. ICRA '09. IEEE International Conference on*, 2009. – ISBN 978-1-4244-2788-8, S. 813–818
- [ZRF12] Zhan, Kai; Ramos, Fabio; Faux, Steven: Activity recognition from a wearable camera. In: *Control Automation Robotics & Vision (ICARCV), 2012 12th International Conference on*, 2012. – ISBN 978-1-4673-1871-6, S. 365–370
- [ZHY09] Zheng, Vincent Wenchen; Hu, Derek Hao; Yang, Qiang: Cross-domain activity recognition. In: *ACM International Conference Proceeding Series*, 2009. – ISBN 9781605584317, S. 61–70
- [ZMH<sup>+</sup>12] Zhu, Zack; Mazilu, Sinziana; Hardegger, Michael; Plotnik, Meir; Hausdorff, Jeffrey M.; Roggen, Daniel; Tröster, Gerhard: Real-Time Detection of Freezing of Gait for Parkinson's Disease Patients via Smartphone. In: *Adjunct Proceedings of the 10th International Conference on Pervasive Computing (Pervasive 2012)*, 2012
- [ZX14] Zongjian, He; Xiaolin, Bai: A wearable wireless body area network for human activity recognition. In: *Ubiquitous and Future Networks (ICUFN), 2014 Sixth International Conf on*, 2014, S. 115–119
- [ZBB<sup>+</sup>08] Zouba, Nadia; Boulay, Bernard; Bremond, Francois; Thonnat, Monique: Monitoring Activities of Daily Living (ADLs) of Elderly Based on 3D Key Human Postures, Bd. 5329. In: CAPUTO, Barbara; VINCZE, Markus (Hrsg.): *Cognitive Vision* : Springer Berlin Heidelberg, 2008 (Lecture Notes in Computer Science). – ISBN 978-3-540-92780-8, S. 37–50
- [ZCA12] Zulkifli, N.S.A.; Che Harun, F. K.; Azahar, N. S.: XBee wireless sensor networks for Heart Rate Monitoring in sport training. In: *2012 International Conference on Biomedical Engineering (ICoBE)*, 2012, S. 441–444

---

**Dipl.-Inform. Sascha Feldhorst**, wissenschaftlicher Mitarbeiter am Lehrstuhl für Förder- und Lagerwesen (FLW) der Fakultät Maschinenbau an der TU Dortmund.

**Prof. Dr. Michael ten Hompel**, Inhaber des Lehrstuhls für Förder- und Lagerwesen der TU Dortmund und geschäftsführender Leiter des Fraunhofer-Instituts für Materialfluss und Logistik IML.

Adresse:  
Lehrstuhl für Förder- und Lagerwesen,  
Technische Universität Dortmund,  
Joseph-von-Fraunhofer-Str. 2-4,  
44221 Dortmund, Deutschland,  
Telefon: +49 231 755-4073, Fax: +49 231 755-4768,  
E-Mail: sascha.feldhorst@tu-dortmund.de