

Analyse der Einflussfaktoren beim Einsatz von BLE basierten Prozessanalyse Werkzeugen in der Intralogistik

Pierre Grzona, Keyur Raval, Philipp Wilsky, Matthias Thürer

Professur Fabrikplanung und Intralogistik, Fakultät Maschinenbau, TU Chemnitz, Chemnitz

Kurzbeschreibung: Ziel dieser Arbeit ist es, den Einsatz einer auf Bluetooth Low Energy basierenden Prozessanalyse Technologie in einer industrienahen Versuchsumgebung zu erproben und auf mögliche Einflussparameter auf die Ergebnisse zu untersuchen. Für die Untersuchung wurden 2 typischen Ressourcen der Intralogistik ausgewählt. Einerseits wurden Experimente mit einem Fahrerlosentransportsystem als auch mit Personen in einem Montagesystem mit spezifischen logistischen Aufgaben durchgeführt. Als Maßgröße für die Beurteilung wurde die gemessene Signalstärke zur Verortung identifiziert. Durch den Zugriff auf die Rohdaten mittels eines Open Source Datenanalysewerkzeuges (Knime) konnten Faktoren wie Ausrichtung und Positionierung der Sender, Störgrößen in der Umwelt wie bspw. andere Maschinen und Einrichtungen aber auch die Positionierung der Empfänger identifiziert werden.

[Schlüsselwörter: Prozessanalyse, Intralogistik, Einflussfaktoren, Aktivitätserkennung]

1 EINLEITUNG

Industrie 4.0-Paradigmen werden aufgrund ihrer Auswirkungen auf die Effizienz, Produktivität und Qualität der Leistung von Unternehmen zunehmend in Produktionsumgebungen eingesetzt [1]. Obwohl die vierte industrielle Revolution bereits im Gange ist und Fortschritte bei der Automatisierung von Fabriken gemacht wurden, liegen vollständig automatisierte Anlagen noch in weiter Ferne. In vielen Fabriken und Lagern, vor allem im Bereich der Logistik, ist menschliche Arbeit noch immer ein wichtiger Faktor. Manuelle Prozesse sind daher häufig Gegenstand von Optimierungsbemühungen. Um diese manuellen Prozesse zu verstehen, werden häufig manuelle Analysen (REFA) oder Zeitstudien (Methods-Time Measurement; MTM) eingesetzt [2].

Die Verbesserung der Produktivität von Industrieanlagen ist eine der größten Herausforderungen in der Fertigung und wirkt sich direkt auf die Rentabilität der Anlagen aus [3]. Da die manuelle Arbeit gerade in Hochlohnländern einer der Hauptkostentreiber ist, ist die Dauer der manuellen

Prozesse von entscheidender Bedeutung für den Betrieb. Die Kenntnis der Zeitkontingente manueller Tätigkeiten hilft, Optimierungspotenziale im Prozess zu finden [4].

Für die Analyse von Prozessen in der Intralogistik kommen eine Vielzahl von Methoden zum Einsatz. Ein Großteil dieser Methoden basieren hierbei auf konventionellen Datenaufnahmen wie Beobachtungen oder Modellierungsansätzen auf Basis von Planzeiten. Zu nennen sind hierbei Methoden aus dem Lean Management wie die Wertstromanalyse zur Aufdeckung von Verschwendungen im Gesamtprozess oder Methoden zur Analyse von Zeitaufwände für spezifische Teilprozesse in der Intralogistik wie REFA Zeitaufnahmen oder Methods-Time-Measurement Studien [5]. In den letzten Jahren setzt sich hierbei die Notwendigkeit von datenbasierten Ansätzen durch, um diese Prozesse zu analysieren [6]. Einerseits kann dies durch die Analyse von vorhanden Buchungsdaten erfolgen, um mittels Process Mining den Gesamtmaterialfluss zu analysieren, umso detailliertere Einblicke zu erhalten, als wie es mit anderen Methoden möglich wäre [7]. Aber auch der Einsatz von zusätzlicher Sensorik zur Analyse manueller Arbeitsvorgänge bspw. als sogenanntes Motion Mining (MM) erfährt Verbreitung [8]. Gleichzeitig erfahren auch die Technologien weitere Untersuchungen hinsichtlich ihrer Planbarkeit in Produktionssystemen [9].

Zielsetzung dieser Arbeit ist es den Einsatz vorgenannte MM-Technologie in einer industrienahen Experimentierumgebung näher zu untersuchen und mögliche Einflussparameter bei der Anwendung zu untersuchen.

2 STAND DER TECHNIK FÜR DIE PROZESSANALYSE IN DER INTRALOGISTIK

Lean Management ist eine kundenorientierte Produktionsphilosophie, die auf die Beseitigung von Verschwendung setzt, um die Produktion ständig zu verbessern [10]. Technologie in der Produktion sollte helfen, die Komplexität zu reduzieren und verschwenderische Aktivitäten zu identifizieren [11]. Während Verschwendung durch Transport, Lagerhaltung, Wartezeiten, Überbearbeitung und

Überproduktion leicht feststellbar ist, ist die Verschwendung durch Bewegung aufgrund ihres flüchtigen Charakters schwer zu ermitteln [9].

Derzeit existieren unterschiedliche Methoden zur Erfassung manueller Arbeit, sei es im Bereich der Effizienz oder der Ergonomie. Die manuelle Zeiterfassung, wie sie top-down bei der REFA- oder bottom-up mittels der MTM-Methode erfolgt, ist oft sehr zeitaufwendig und erfordert einen in der respektiven Methode geschulten Experten. In dieser Ressourcenbeschränkung ergibt sich auch die Herausforderung für den praktischen Einsatz und Durchdringung in Unternehmen. Vor allem Prozesse mit stochastischen oder azyklischen Elementen stellen hier eine Herausforderung dar. Prozesse, die Wartezeiten auf technische Hilfsmittel oder den Einsatz mehrerer Maschinen beinhalten, lassen sich mit den derzeitigen Methoden nur schwer abbilden. Dies führt oft dazu, dass solche Prozesse ganz weggelassen werden [8].

Die Tätigkeitsstrukturanalyse dient der Erfassung aller Tätigkeiten eines Mitarbeiters während eines definierten Zeitraums. Die aus den Aktivitäten gewonnenen Daten (z.B. Dauer) werden in einen Gesamtprozesszusammenhang gestellt. Ziel ist es, die nicht wertschöpfende Zeit zu ermitteln, die für Tätigkeiten wie Dokumentation oder die zurückgelegte Strecke aufgewendet wird [12].

Ein weiterer Aspekt ist die Erfassung von Bewegungs- und Spielzeiten beispielsweise von logistischen Betriebsmitteln. Hier hat in den letzten Jahren der Einsatz von Process Mining ein Potenzial gezeigt, um datenbasiert detaillierter Einblick in die Ist-Situation, als Bestandteil von Logistikplanungen, zu erhalten [7].

2.1 METHODEN UND TECHNIKEN ZUR AKTIVITÄTSERKENNUNG

Die Erkennung menschlicher Aktivitäten ist im Zeitalter des Internets der Dinge und der KI-Technologien zu einem wichtigen Forschungsbereich geworden [13, 14]. Die Erkennung menschlicher Aktivitäten spielt eine entscheidende Rolle bei der Überwachung und Analyse menschlicher Verhaltensweisen mit verschiedenen Arten von Sensoren [14]. Aktivitätserkennung kann definiert werden als die Fähigkeit, die aktuelle Aktivität auf der Grundlage von Informationen, die von verschiedenen Sensoren empfangen werden, wiederzuerkennen/zu erkennen [15, 16]. Die Sensordaten werden nach Mustern analysiert, die auf eine Reihe bekannter menschlicher Aktivitäten zurückgeführt werden können [10]. Bei diesen Sensoren kann es sich um Kameras, tragbare Sensoren, an Gegenständen des täglichen Gebrauchs angebrachte oder in der Umgebung angebrachte Sensoren handeln [17].

Ein vielversprechender Ansatz ist nach *Harris et al.* die technische Unterstützung und Automatisierung der Erfassung und Analyse manueller Arbeitsabläufe. Hierfür stehen mittlerweile verschiedene Technologien wie BLE

basierte automatische Aktivitätserkennung [2, 4], WLAN-basierte Lokalisierungstechnologien [18] oder kamerabasierte Motion-Capture-Lösungen in Kombination mit digitalen Menschmodellen [19] zur Verfügung, die einen wertvollen Beitrag dazu leisten können.

Wearable Technology ist eine allgegenwärtige Lösung zur Verbesserung der Arbeitseffizienz, zur Steigerung der Leistung der Arbeitnehmer und zur Schaffung von Interaktionen zwischen den Nutzern und dem Arbeitsplatz, jederzeit und überall [20]. Aktivitätserkennung mit tragbaren Sensoren ist ein weiträumiges Forschungsgebiet [21, 22]. Tragbare IoT-Sensoren wie Smartwatches und Smartphones, die in der Lage sind, Beschleunigung, Orientierung und Standort zu messen, werden häufig zur Erkennung menschlicher Aktivitäten wie Gehen, Stehen, Sitzen oder Schlafen verwendet. Solche IoT-Geräte und erkannten Aktivitäten sind jedoch möglicherweise nicht für industrielle Umgebungen geeignet, in denen die Arbeitnehmer ihre Position an mehreren Arbeitsplätzen ständig wechseln [23].

Bei der bildgestützten Erkennung menschlicher Aktivitäten werden menschenbezogene Merkmale aus einem Videostrom extrahiert, der durch die Positionierung einer Kamera in der Umgebung gewonnen wird [14]. Auf Computer Vision basierende Methoden werden in einigen Industrieversuchen eingesetzt, um menschliche Aktivitäten zu erkennen, die spezifisch für entsprechende industrielle Umgebungen sind [24]. Obwohl diese Methode menschliche Handlungen visuell darstellen kann, wirft sie Bedenken hinsichtlich des Datenschutzes auf, und ihre Effizienz hängt bspw. vom Standard der Hintergrundbeleuchtung ab. Im Vergleich dazu bietet das auf tragbaren Sensoren basierende System zur Erkennung menschlicher Aktivitäten mehrere Vorteile, darunter die Unempfindlichkeit gegenüber externen Faktoren und eine höhere Genauigkeit, während gleichzeitig Bedenken hinsichtlich der Vertraulichkeit ausgeräumt werden [14]. Aufgrund der geringen Kosten und des Fortschritts in der Sensortechnologie hat sich ein Teil der Forschung im Bereich der Erkennung menschlicher Aktivitäten auf einen sensorbasierten Ansatz verlagert [17] und wird zunehmend relevanter in industriellen Umgebungen [24]. Beim Wearable-Konzept muss der Benutzer die Sensoren bei jeder Aktivität bei sich tragen [17].

2.2 AKTIVITÄTSERKENNUNG MIT TRAGBAREN SENSOREN

In den letzten zwei Jahrzehnten gab es Bemühungen, die Erfassung und Analyse menschlicher Bewegungen und manueller Prozesse durch den Einsatz drahtloser Sensornetzwerke zu automatisieren und zu vereinfachen. Die Automatisierung der Aufzeichnung und Analyse der Bewegungen wird durch die Miniaturisierung der Sensoren und die fortschreitende Entwicklung der Mustererkennung und Signalverarbeitung gefördert [8].

Eine marktreife Technologie zur Erfassung und Analyse von manuellen Prozessen ist MM des Anbieters MotionMiners, Dortmund. Abbildung 1 zeigt eine schematische Darstellung der Funktionsweise von MM. Zur Erfassung von Bewegungsdaten verwendet die Technologie zwei Bewegungssensoren an den Handgelenken der Mitarbeiter und einen Sensor am Gürtel. Sie nutzt ein Beacon-Netzwerk, das aus Bluetooth-Sendern und einem vom Mitarbeiter getragenen Empfänger in Form eines Smartphones besteht (Produktgeneration Gen3). Dieses Beaconnetzwerk wird verwendet, um einen Mitarbeiter während eines Prozesses in verschiedenen Arbeitsbereichen oder Regionen zu lokalisieren und Daten über Laufwege und Körperhaltungen zu erfassen. Die gesammelten Bewegungs- und Lokalisierungsdaten werden dann mit einem auf maschinellem Lernen basierenden Mustererkennungsverfahren verarbeitet, um Bewegungen und Prozesse zu identifizieren [12].

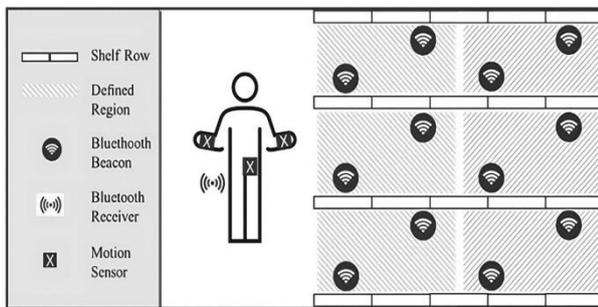


Abbildung 1. Funktionsweise der MM-Hardware [12]

2.3 METHODOLOGIE

Die MM-Technologie basiert auf einer Kombination aus BLE-Sendern, Beacons, und entsprechenden Empfängern. Die Kombination mehrerer dieser Beacons in einem Bereich ermöglicht die entsprechende Zuordnung von Mitarbeitern und logistischen Ressourcen zu Bereichen in der Anlage. Zu diesem Zweck werden die Informationen über die empfangene Signalstärke in einer Online-Plattform verarbeitet. Beim Einsatz der Technologie stellen sich zwei Forschungsfragen:

RQ1: Welche Analyseszenarien können in der Intralogistik auftreten?

RQ2: Wie können die gesammelten Daten des MM mittels einer Data Analytics Plattform untersucht werden?

RQ3: Welches sind die Faktoren, die die Genauigkeit der Messungen beeinflussen?

Zum Einsatz kommen einerseits ein Literaturreview als auch Experimente innerhalb der Experimentier- und Digitalfabrik (EDF) der Professur Fabrikplanung und Intralogistik als integrierte Lehr-, Forschungs- und Transferumgebung [25].

3 UNTERSUCHUNGEN:

Ziel dieser Arbeit ist es, den Einsatz der MM-Technologie in einer industrieorientierten Versuchsumgebung zu untersuchen und mögliche Einflussparameter auf die Ergebnisse zu prüfen. Zu diesem Zweck wurde eine Reihe von Szenarien durchgeführt, die auf typischen Fragestellungen in der Planung von intralogistischen Prozessen basiert. Alle Experimente wurden in der experimentellen und digitalen Fabrik des Lehrstuhls für Fabrikplanung und Intralogistik durchgeführt. Die Experimente wurden so konzipiert, dass sie die realen industriellen Szenarien nachbilden / simulieren. Die durchgeführten Experimente können hauptsächlich in zwei Kategorien eingeteilt werden: 1) nicht-menschliche Ressourcen in Form eines Fahrerlosen Transport Systems (FTS) und 2) menschliche Ressourcen.

3.1 NICHT-MENSCHLICHE RESSOURCEN (FTS)

Für diese Versuchskategorie wurde ein FTS zur Datenerfassung eingesetzt. Als mögliches Szenario wurde der grundlegende Produktionszyklus betrachtet, der aus 4 Schritten besteht, wie z.B. Übernahme Produktionsauftrag, Verpackung, Arbeitsstation und Logistik. Ausgehend von diesem Szenario wurden 3 Experimente durchgeführt mit dem Ziel, die beeinflussenden Parameter herauszufinden, wie z.B.:

- Anzahl der Regionen und Größe der Region,
- Anzahl der Beacons und Positionierung dieser,
- Anzahl der Sensoren und Positionierung dieser,
- und Einfluss von Hindernissen auf die Signalstärke.

3.1.1 EXPERIMENT 1

Platzierung der Beacons: Die Anzahl der Regionen betrug 23 und die Anzahl der platzierten Beacons 26. Die Platzierung der Beacons war bei diesem Experiment nicht einheitlich und standardisiert. Einige wurden in Hüfthöhe platziert (Abbildung 2 - links), andere in Überkopfhöhe (Abbildung 2 - rechts).



Abbildung 2. Platzierung eines Beacons, links Hüfthöhe, rechts Überkopf

Platzierung der Sensoren: Es standen insgesamt 8 Sensorensätze zur Verfügung, die von A bis H benannt wurden. Jeder Sensorensatz besteht aus 3 Sensoren, nämlich L, T und R. Ein Sensorensatz (A) wurde vor dem FTS platziert (Abbildung 3 - links) und die restlichen Sensorensätze (B-E) wurden gesammelt und nach dem Zufallsprinzip zusammen in einem Kleinladungsträger (KLT) platziert (Abbildung 3 - rechts). Die Box mit den Sensoren wurde dann in der Mitte des FTS platziert in einem Durchlaufregal.



Abbildung 3. Platzierung der Sensorensätze, links Montage an der Front, rechts Platzierung in einem KLT

3.1.2 EXPERIMENT 2

Platzierung der Beacons: Die Anzahl der Regionen betrug 16 und die Anzahl der platzierten Beacons 18. Für dieses Experiment wurde die Platzierung der Beacons einheitlich und standardisiert. In Anlehnung an das erste Experiment wurden alle Baken für dieses Experiment in Hüfthöhe platziert (Abbildung 2 - links).

Platzierung der Sensoren: Für die Messung wurden insgesamt 8 Sensorensätze verwendet. Ein Satz (A) wurde vor dem FTS platziert (Abbildung 3 - links). In ähnlicher Weise wurden die Sensoren B, C, D und E an der Unterseite eines Transportgestelles des FTS platziert (siehe Abbildung 4). Die restlichen Sensoren (F, G, H) wurden nach dem Zufallsprinzip in einem KLT platziert (Abbildung 3 - rechts). Der KLT mit den Sensoren wurde dann in der Mitte des FTS platziert, ähnlich wie beim ersten Experiment.



Abbildung 4. Platzierung der Sensoren an der Unterseite des FTS

3.1.3 EXPERIMENT 3

Platzierung der Beacons: Bei diesem Experiment wurden 14 Regionen und 24 Baken platziert. Die Platzierung der Baken war einheitlich und standardisiert. In Anlehnung an das erste Experiment wurden für dieses Experiment alle Baken in Hüfthöhe platziert (Abbildung 2 -links).

Platzierung der Sensoren: Die Platzierung der Sensoren war identisch mit Experiment 2.

3.2 MENSCHLICHE RESSOURCEN

Neben dem oben beschriebenen Szenarien wurde in einem nächsten Schritt ein weiteres Szenario durchgeführt. Dieses Szenario wurde mit den menschlichen Ressourcen als Teil des Lean-Workshops durchgeführt. Es wurde hierbei eine Montagesituation nachgestellt, in der Studierende den Einsatz von verschiedenen Fabrikplanungs- und Lean-Methoden erlernen und anwenden sollten sowie die Verbesserungen im Rahmen ihrer Montagetätigkeiten erfahren sollten. Dabei wurden die verschiedenen Lean-Layouts analysiert, und die Maßnahmen wurden von den Mitarbeitenden wie in der realen Welt ergriffen. Dies beinhaltete Layoutveränderungen, Prozessverbesserungen in Form einer Austaktung der Montage und die Änderung der Auftragssteuerung von einer Push- hin zu einer Kanban-Steuerung. Hierzu wurden bis zu 8 Arbeitsstationen in 11 Regionen mit 15 Beacons ausgestattet. Zum Einsatz kamen 8 Sensorensätze wovon 5 für die menschlichen Ressourcen sowie 3 zur Auftragsnachverfolgung eingesetzt wurden.

3.3 TESTS ZUR POSITIONIERUNG VON BEACONS

Nach der ersten Reihe von Experimenten stellte sich die Frage nach der idealen Positionierung der Beacons, insbesondere bei Szenarien die noch nicht automatisch über die Plattform ausgewertet können. Der Hauptzweck dieses Szenarios ist die Beantwortung der Frage, welche Position der Beacons besser ist, ob die Baken horizontal oder vertikal platziert werden sollten und welche Einflüsse ggf. noch mit zu beachten sind.

Um diese Frage zu beantworten, wurde der Versuchsaufbau wie in Abbildung 5 dargestellt konzipiert mit äquidistanten Positionen der Beacons zu den Sensoren. Für dieses Experiment wurden insgesamt 6 Sensoren verwendet, die wie in Abbildung 6 dargestellt auf baugleichen Ständern positioniert wurden.

Für diesen Aufbau wurden insgesamt 12 Beacons verwendet und wie in den Abbildungen 5 und 6 dargestellt positioniert. Die Beacons wurden so positioniert, dass sie den gleichen Abstand zwischen den beiden nächstgelegenen Sensoren bilden, sodass von einem Sensor immer 2 Beacons bzw. 2 Sensoren immer das Signal eines Beacons im gleichen Abstand erfassen konnten. Der anfängliche Abstand betrug 2 Meter und wurde in Meter Schritten auf 7 Meter erhöht. Diese Anordnung der Baken ergab zwei

Gruppen. Eine, die sich auf der linken Seite befand, wurde horizontal und eine, die sich auf der rechten Seite befand, wurde vertikal positioniert. Sowie eine Reihe von Sensoren auf der gegenüberliegenden Seite des Raumes mit Abständen im Bereich von 6-10 Meter. Bei jeder Entfernung wurden also zwei Messungen durchgeführt, eine mit der horizontalen und eine mit der vertikalen Position der Beacons.

Es wurden insgesamt 6 Messungen von jeweils 10 Minuten Dauer durchgeführt, um ggf. Schwankungen der Signalstärke zu erkennen. Nach jeder Messung wurden die Sensoren um eine Position im Uhrzeigersinn verschoben, bis die Sensoren in die ursprüngliche Position zurückkehrten. Nach der Erfassung der Messdaten wurde die Signalstärke zwischen den beiden Beaconpositionen verglichen.

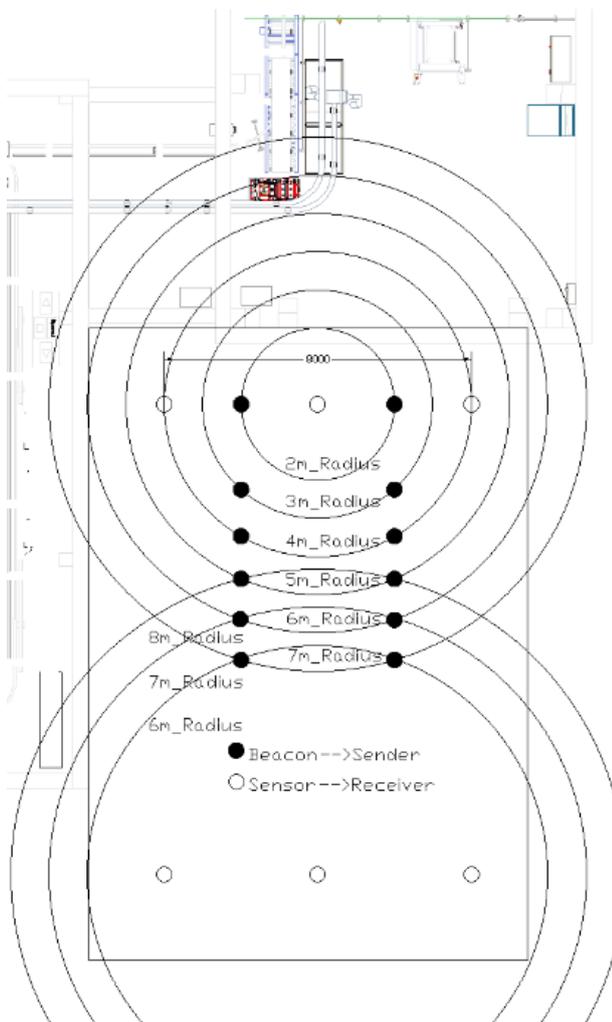


Abbildung 5. Layout für Versuchsaufbau Beacontests

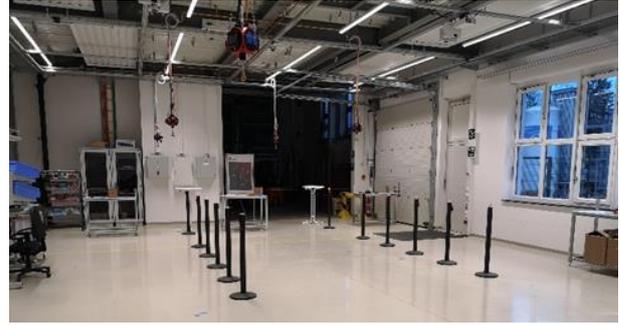


Abbildung 6. Versuchsaufbau in EDF für Beacontests

4 ERGEBNISSE DER EXPERIMENTE

4.1 ANALYSE DER NICHT-MENSCHLICHEN RESSOURCEN (FTS)

4.1.1 ANALYSE EXPERIMENT 1

Die ersten Experimente wurden mit der MM eigenen MPI Plattform durchgeführt. Hierbei ist der erste Schritt der Prozessanalyse die Definition des zu untersuchenden Prozesses. Die Prozessdefinition beeinflusst die Analyse, da das System versucht, die Daten auf der Grundlage des vom Benutzer definierten Prozesses zu verstehen. Nach der Definition des Prozesses kann der Benutzer die Daten durch die Erstellung verschiedener Diagramme analysieren.

Eines der Diagramme ist die Prozessverteilung. Dieses Diagramm zeigt die Menge der erfassten Daten, die von der Software entsprechend dem definierten Prozess zugeordnet wird und kann dementsprechende etwas über die Qualität der erfassten Signalstärken sagen. Mit anderen Worten, es gibt ein Bild der gebuchten Daten entsprechend dem definierten Prozess. Das Prozessverteilungsdiagramm für das Beispiel 1 ist in Abbildung 7 zu sehen. Es ist zu erkennen, dass nur etwa 22 % der erfassten Daten dem definierten Prozess entsprachen und die Mehrheit von etwa 78 % unbekannt war und somit die erfassten Daten keinem Muster entsprachen.

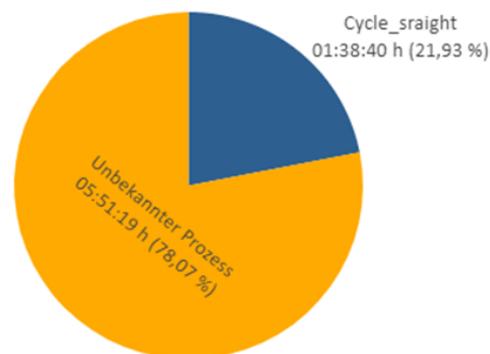


Abbildung 7. Prozessverteilungsdiagramm für Experiment 1

Daher ist die nächste wichtige Frage, in welchen Regionen die Daten gebucht wurden. Das Diagramm der regionalen Labelverteilung gibt die nötigen Informationen. Für Experiment 1 ist dies in Abbildung 8 dargestellt. Es ist ersichtlich, dass die meisten der gesammelten Daten in den Fehlerregionen und nicht in den Regionen, die dem tatsächlichen Weg des FTS folgen, gebucht wurden. Hier ist zu ergänzen, dass der Versuchsaufbau so gewählt wurde, dass sich knapp (ca. 50 cm) neben dem Fahrweg des FTS diese Fehlerregionen befanden.

Ein weiterer Parameter war die Zykluszeit zu analysieren, da diese durch den Einsatz eines FTS konstant gehalten werden konnte. Zur Analyse der Zykluszeit wurde die Verteilung der Durchlaufzeit pro Prozessdefinition und ein Boxplot-Diagramm verwendet. Das Boxplot-Diagramm für Versuch 1 ist in Abbildung 9 zu sehen.

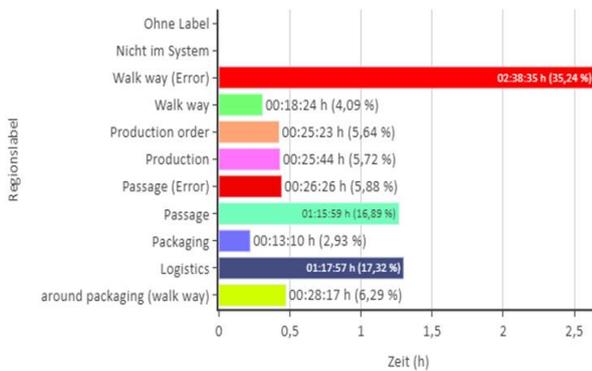


Abbildung 8. Diagramm der regionalen Labelverteilung für das Experiment: 1

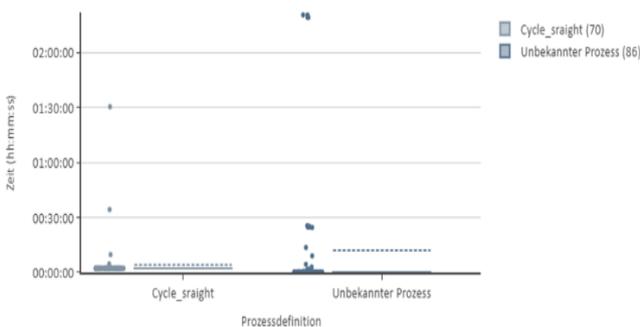


Abbildung 9. Boxplot für Experiment 1

Aus Abbildung 9 ist ersichtlich, dass die Anzahl der von der Software ermittelten definierten Zyklen 70 und die der nicht definierten Prozesszyklen 86 beträgt. Der Median der definierten Zyklen betrug 2 Minuten und 16 Sekunden. Der Median für die nicht definierten Prozesszyklen lag bei 11 Sekunden. Es gibt einige Zyklen im definierten Prozess (Cycle_sraight), die außerhalb des Medianbereichs liegen. Die detaillierte Analyse dieser Zyklen auf der Grundlage ihrer Zyklusnummer ist ebenfalls über die MM-Plattform

möglich. Für das besser Verständnis der Einflüsse war es notwendig die einzelnen Zyklen im Detail zu untersuchen. Nach der Analyse dieser wurde festgestellt, dass es sich nicht um einen einzelnen Zyklus handelt, sondern um Mehrere, die zu einem Einzigem zusammengefasst wurden, so dass sich jeweils Vielfache der ursprünglichen Grundzeit des FTS ergaben.

4.1.2 ANALYSE EXPERIMENT 2

Für dieses Experiment wurde die Prozessdefinition für das FTS in zwei verschiedenen Zyklen separiert, um das Experiment realistischer zu gestalten, da in einer realen industriellen Umgebung mehr als ein Prozess untersucht wird. Gleichzeitig wurde auch die Granularität der Regionen um 7 reduziert und lag trotz dessen noch wesentlich über den Empfehlungen in der minimalen Größe der Regionen.

Eine ähnliche Analyse wurde auch für Versuch 2 durchgeführt. Das Prozessverteilungsdiagramm für Versuch 2 ist in Abbildung 10 zu sehen. Aus Abbildung 10 ist ersichtlich, dass etwa 51 % der gesammelten Daten als regelmäßiger Zyklus und 38 % der gesammelten Daten als runder Zyklus verbucht wurden. Insgesamt wurden rund 89 % der gesammelten Daten als die definierten Prozesse erkannt. Und nur 11 % der gesammelten Daten wurden als undefinierter Prozess verbucht. Dies ist eine erhebliche Verbesserung gegenüber dem ersten Versuch.

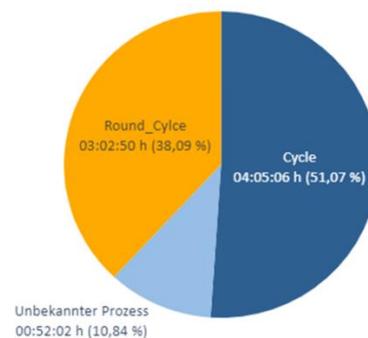


Abbildung 10. Prozessverteilungsdiagramm für Experiment 2

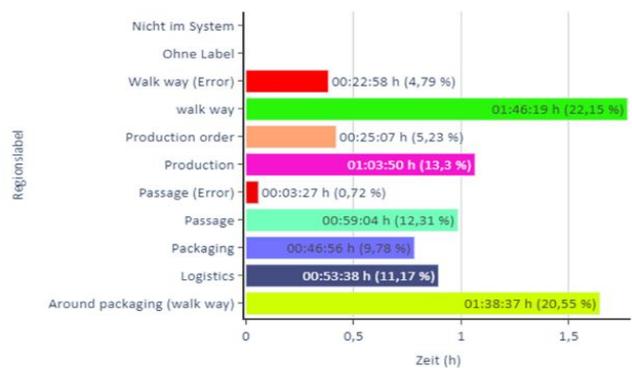


Abbildung 11. Diagramm der regionalen Labelverteilung für Experiment: 2

Das Diagramm der regionalen Etikettenverteilung für Versuch 2 ist in Abbildung 11 dargestellt. Es ist ersichtlich, dass die in den Fehlerregionen verbuchten Daten im Vergleich zum ersten Versuch deutlich zurückgegangen sind. Mit anderen Worten: Die meisten Daten wurden in den Regionen gebucht, die in den tatsächlichen Pfad der Bewegung des FTS fallen.

Die Verteilung der Durchlaufzeit pro Prozessdefinition oder das Boxplot-Diagramm für Experiment 2 ist in Abbildung 12 zu sehen. Es ist ersichtlich, dass die Anzahl der von der Software identifizierten regelmäßigen Zyklen 237, die Anzahl der runden Zyklen 491 und die Anzahl der nicht definierten Prozesszyklen 20 beträgt. Wichtig ist hierbei, dass bei diesem Experiment 2 verschiedene Zyklen im Schritt der Prozessdefinition definiert wurden. Der Median für den regulären Zyklus beträgt 2 Minuten und 28 Sekunden. Der Median für den runden Zyklus liegt bei 1 Minute und 14 Sekunden. Und der Median für die undefinierten Prozesszyklen beträgt 1 min 42 sec. Ähnlich wie beim ersten Experiment handelt es sich bei den Zyklen, die außerhalb des normalen Zeitbereichs liegen, nicht nur um einzelne Zyklen, sondern um mehrere Zyklen, die zu einem Zyklus zusammengefasst wurden.

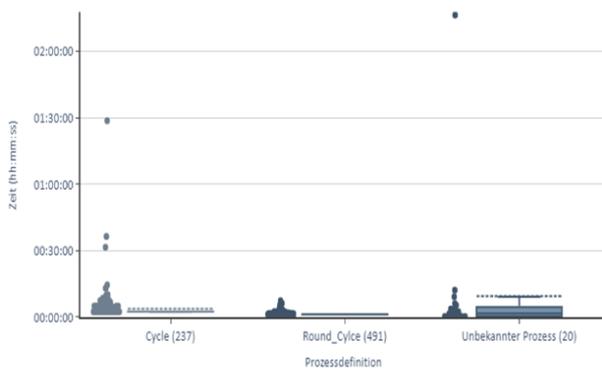


Abbildung 12. Boxplot für Experiment 2

4.1.3 ANALYSE EXPERIMENT 3

Bei diesem Versuch wurde das FTS in einem Zyklus ähnlich wie bei Versuch 1 betrieben.

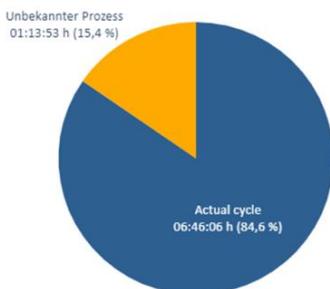


Abbildung 13. Prozessverteilungsdiagramm für Experiment 3

Das Prozessverteilungsdiagramm für Versuch 3 ist in Abbildung 13 zu sehen. Es ist ersichtlich, dass etwa 85 % der gesammelten Daten als der definierte Prozess gebucht wurden. Nur 15 % der gesammelten Daten wurden als undefinierter Prozess verbucht. Das ist eine deutliche Verbesserung gegenüber den ersten Experimenten, insbesondere da das Anbringen und die Entnahme der Sensoren nicht aus den Messreihen aus der Plattform entfernt werden konnten.

Das Diagramm der regionalen Labelverteilung für Experiment 3 ist in Abbildung 14 dargestellt. Es zeigt die erwarteten Ergebnisse. Es gibt keine großen Schwankungen bei der Buchung von Daten in verschiedenen Regionen.

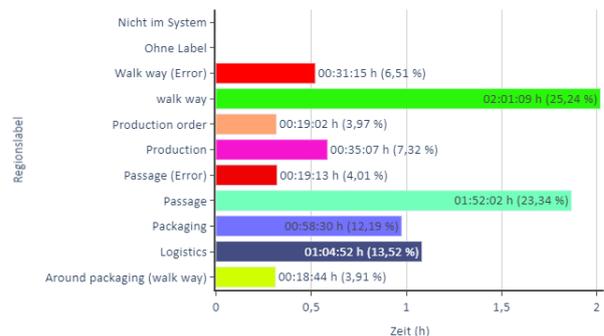


Abbildung 14. Diagramm der regionalen Labelverteilung für das Experiment: 3

Die Verteilung der Durchlaufzeit pro Prozessdefinition oder das Boxplot-Diagramm für das Experiment 3 ist in Abbildung 15 zu sehen. Es ist ersichtlich, dass die Anzahl der von der Software ermittelten tatsächlichen Zyklen 156 und der nicht definierten Prozesszyklen 8 beträgt. Der Median für den tatsächlichen Zyklus beträgt 2 Minuten und 28 Sekunden. Der Median für die nicht definierten Prozesszyklen liegt bei 2 min 57 sec. Ähnlich wie beim ersten Experiment handelt es sich bei den Zyklen, die außerhalb des normalen Zeitbereichs liegen, nicht nur um einzelne Zyklen, sondern um mehrere Zyklen, die zu einem Zyklus zusammengefasst wurden.

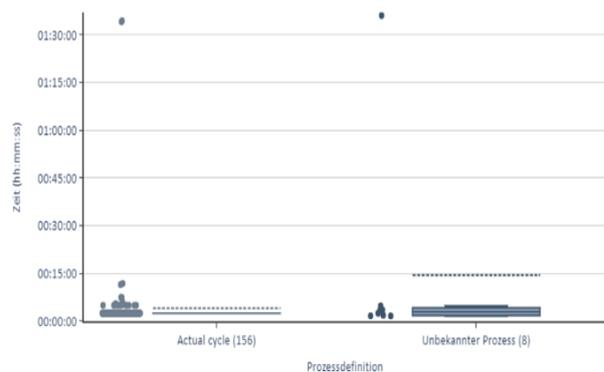


Abbildung 15. Boxplot für Experiment 3

4.2 ANALYSE DER MENSCHLICHEN RESSOURCEN

Im Rahmen der zweiten Untersuchung wurde die Sensoren – wie vom Hersteller angedacht – jeweils an den Mitarbeitenden im Produktionssystem angebracht. Hierbei zeigte sich die erwartete Zuordnung der Prozesse zu den jeweiligen Rollen die den Arbeitsplätzen. Aufgrund der weiter erhöhten Grundflächen je Region konnte auch die Zuordnungsqualität weiter gesteigert werden. Exemplarisch sei hier die Rolle des Meisters herausgegriffen, der in der ersten Workshop Runde die entsprechenden Aufträge zum Montageplatz 1 bringt und die abschließende Qualitätskontrolle und den Warenausgang übernimmt (siehe Abbildung 16).

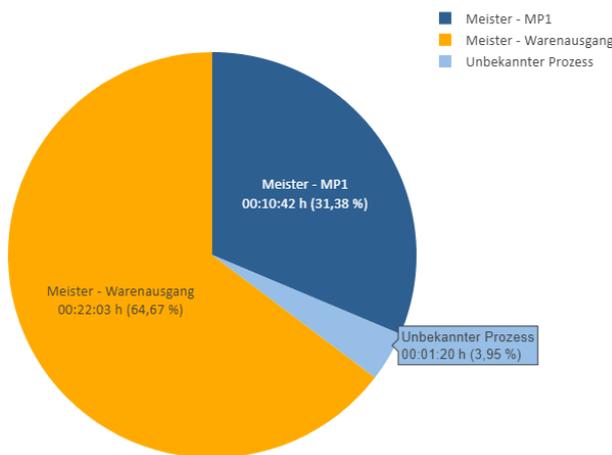


Abbildung 16. Prozessverteilungsdiagramm für Rolle des Meisters im Rahmen des Lean-Workshops

Wie in den vorangegangenen Experimenten wurde hierbei auf die Auswertung aus der Plattform zurückgegriffen, sodass die Messdaten vor ihrer Auswertung nicht auf die reinen, zu messenden Aktivitäten eingeschränkt werden konnten. Neben den Aktivitäten der menschlichen Ressourcen wanderten die Aufträge in Form von KLTs durch den Prozess. Diese wurden hierbei auch mittels Sensoren erfasst. Hier zeigte sich die Herausforderung, dass dies zum Zeitpunkt der Messungen noch nicht innerhalb der Plattform ausgewertet werden konnte, sodass die Auswertung dann mittels Zugriffes auf die Rohdaten (Signalstärken) und KNIME als Data Analytics Plattform durchgeführt wurde (siehe Abbildung 17).

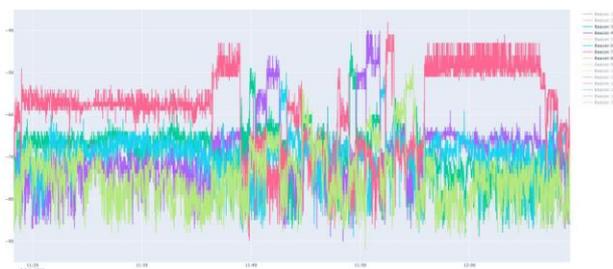


Abbildung 17. Empfangene Signalstärken eines Sensors im Zeitverlauf

Es zeigte sich das Potenzial hiermit noch weitere Einsichten in den Prozess zu erhalten, beispielsweise die Durchlaufzeiten oder auch die Prozesszeiten an den einzelnen Stationen. Zu erkennen ist dies am Verlauf des roten Beacons, der zeigt das der KTL nach einer Wartezeit in das System eingeschleust wird (ca. 1/3 der Zeitreihe), danach die verschiedenen Arbeitsstationen durchläuft und abschließend wieder auf seine Demontage wartet um erneut genutzt zu werden. Gleichzeitig sind auch die Schwankungen der gemessenen Signalstärken zu erkennen. Einerseits resultierend aus den verschiedenen Elementen die sich im System bewegten, aber auch andererseits als spezifische technische Eigenschaften der eingesetzten Sensoren und Beacons.

4.3 ANALYSE DER BAKENPOSITIONIERUNGSTESTS

Im abschließenden Experiment war es erforderlich, die Signalstärke – in dem Fall die Received Signal Strength Indication (RSSI) – der Beacon-Sensoren-Kombination genauer zu analysieren, wofür die KNIME Analytical Software verwendet wurde. Da das Experiment die Neupositionierung der Beacons beinhaltete, war es notwendig, Fehler aus den Daten zu entfernen. Nach der Datenbereinigung wurde ein Vergleich zwischen der Signalstärke der horizontalen und vertikalen Beaconpositionierung für jeden Zyklus durchgeführt. Für diese Analyse wurden ein Liniendiagramm und die statistischen Werte wie Minimum, Maximum, Mittelwert, mittlere absolute Abweichung und Standardabweichung verglichen.

Der Vergleich der Standardabweichung ist in Tabelle 1 dargestellt. Aus Tabelle 1 kann keine konkrete Schlussfolgerung für die optimale Position der Beacons gezogen werden, da aus den Standardabweichungsdaten kein klares Muster erkennbar ist. Die Diskrepanzen in den Daten könnten auf die Unterschiede in der Sensorgenauigkeit zurückzuführen sein. Da in jedem Zyklus ein anderer Sensor verwendet wird, ist es möglich, dass die Genauigkeit der einzelnen Sensoren variiert. Dabei steht H für die horizontale und V für die Vertikale Positionierung der Beacons.

Ein weiterer Vergleich der Mittelwerte ist in Tabelle 2 dargestellt. Die Mittelwerte zeigen ein klares Muster. Die vertikalen Platzierungswerte sind für jeden Zyklus und für jede Entfernung höher als die horizontalen Platzierungswerte. Daher kann aus Tabelle 2 die Schlussfolgerung gezogen werden, dass die vertikale Positionierung der Beacons besser ist als die horizontale Positionierung der Beacons im Hinblick auf die empfangenen Signale an den Sensoren.

Tabelle 1. Vergleich der Standardabweichung

Dis- tanz	Zyklus 1 (B-T)		Zyklus 2 (B-L)		Zyklus 3 (C-L)		Zyklus 4 (C-T)		Zyklus 5 (C-R)		Zyklus 6 (B-R)		Alle Zyklen	
	H	V	H	V	H	V	H	V	H	V	H	V	H	V
2 m	0,13	0,60	0,46	1,74	1,38	1,20	1,36	1,23	1,12	1,83	0,24	0,47	0,57	0,56
3 m	0,38	0,53	0,28	0,57	1,36	2,19	1,15	1,75	1,22	1,77	0,45	0,51	0,49	0,77
4 m	0,48	0,49	0,61	1,23	2,31	2,17	1,30	2,14	2,13	2,35	0,84	0,41	0,78	0,88
5 m	0,50	0,48	0,50	1,02	2,64	1,05	2,60	1,13	2,45	1,33	0,43	0,95	1,14	0,28
6 m	0,63	1,34	0,48	0,35	2,33	2,37	2,55	1,59	2,61	2,00	0,55	0,36	1,07	0,83
7 m	0,58	0,69	0,56	0,68	1,14	1,28	1,30	1,04	1,40	1,24	0,61	0,82	0,39	0,27

Tabelle 2. Mittelwertvergleich der RSSI

Dis- tanz	Zyklus 1 (B-T)		Zyklus 2 (B-L)		Zyklus 3 (C-L)		Zyklus 4 (C-T)		Zyklus 5 (C-R)		Zyklus 6 (B-R)	
	H	V	H	V	H	V	H	V	H	V	H	V
2 m	-69	-57	-69	-57	-69	-58	-67	-55	-68	-57	-68	-56
3 m	-75	-60	-76	-60	-75	-61	-73	-60	-74	-60	-75	-61
4 m	-79	-57	-82	-57	-82	-57	-77	-55	-80	-56	-80	-56
5 m	-72	-71	-72	-69	-74	-71	-72	-69	-73	-69	-73	-69
6 m	-65	-58	-64	-57	-67	-58	-65	-57	-65	-57	-65	-58
7 m	-80	-67	-80	-65	-79	-67	-78	-66	-78	-65	-78	-66

5 KRITISCHE WÜRDIGUNG UND ERKENNTNISSE

Nach der Durchführung der verschiedenen Experimente mit verschiedenen Einstellungen und Parametern und in unterschiedlichen Situationen lassen sich die Erkenntnisse wie nachfolgend zusammenfassen.

Beim Einsatz der Prozessanalysetechnologie ist Prozessdefinition ist ein entscheidender Schritt bei der Datenanalyse. Die grundlegenden technischen Einschränkungen der BLE-Lokalisierungstechnologie können nur eingeschränkt umgangen werden, sodass Übergänge zu anderen Aktivitäten unter 0,5m vermieden werden sollten. Dies hat erhebliche Auswirkungen darauf, wie gut das System die Buchung der Daten interpretiert. Die empfohlene Größe des Bereichs (mindestens 2*2 Meter) sollte das Ziel sein. Eine geringere Größe des Bereichs führt zu ungenauen Messungen. Eine standardisierte Positionierung der Beacons führt zu einer wesentlich besseren Messgenauigkeit.

Die vertikale Positionierung der Beacons bietet eine signifikant bessere empfangene Signalstärke auf gleicher Entfernung als die horizontale Positionierung. Daher sollte die optimale Position für die Platzierung der Beacons in vertikaler Richtung liegen. Zusammenfassend lässt sich sagen, dass die Technologie sich auch für ad-hoc Aufnahmen im Rahmen von Workshops bei entsprechender Einmessung eignet, um logistische Kennzahlen wie Zykluszeiten, Durchlaufzeiten zu erheben. Dies bietet sich auch an für Untersuchungen von Produktionssystemen bei denen durch

die Anzahl von Untersuchungsgegenständen oder die Weitläufigkeit der Bewegungsbereiche bei manuellen Prozessen etablierte Methoden wie Zeitstudien oder Selbstaufschreibungen zu langwierig oder nicht genügend Daten in der benötigten Qualität liefern würden. Durch die Einmessung der entsprechenden Untersuchungsbereiche und damit auch die Aufnahme der örtlichen Gegebenheiten sowie etwaiger Störgrößen, kann schnell zwischen verschiedenen Aufnahmesituation in einem Raum gewechselt werden.

Einschränkend zur Versuchsauswertung ist zu sagen, dass die Daten zur Signalstärke mit dem untersuchten System ermittelt wurden, sodass hier auch die spezifischen technischen Eigenschaften zum Tragen kommen und dies zu etwaigen Messfehlern führen kann. Desweiteren wurden die Versuche in einer Umgebung durchgeführt in der schon weitere Funktechnologie wie bspw. WLAN auf 2,4 GHz, UWB sowie weitere BLE-Ortungssysteme genutzt werden. Eine gegenseitige Beeinflussung konnte hierbei bis jetzt nicht dokumentiert werden.

DANKSAGUNGEN

Dieser Beitrag entstand im Rahmen des Projekts „KISS – KI-gestütztes Rapid Supply Network“, das vom Bundesministerium für Wirtschaft und Klimaschutz (BMWK) innerhalb des „Innovationswettbewerbs Künstliche Intelligenz“ unter dem Kennzeichen 01MK22001B gefördert wird.

LITERATUR

- [1] FANTONI, Gualtiero ; AL-ZUBAIDI, Salam Qaddoori ; COLI, Elena ; MAZZEI, Daniele: *Automating the process of method-time-measurement*. In: *International Journal of Productivity and Performance Management* 70 (2021), Nr. 4, S. 958–982
- [2] GRZESZICK, Rene ; LENK, Jan Marius ; RUEDA, Fernando Moya ; FINK, Gernot A. ; FELDHORST, Sascha ; HOMPEL, Michael ten: Deep Neural Network based Human Activity Recognition for the Order Picking Process. In: YORDANOVA, Kristina; SCHRÖDER, Max; BADER, Sebastian; KIRSTE, Thomas (Hrsg.): *Proceedings of the 4th International Workshop on Sensor-based Activity Recognition and Interaction*. New York, NY, USA : ACM, 2017, S. 1–6
- [3] GEORGAKOPOULOS, Dimitrios ; JAYARAMAN, Prem Prakash ; FAZIA, Maria ; VILLARI, Massimo ; RANJAN, Rajiv: *Internet of Things and Edge Cloud Computing Roadmap for Manufacturing*. In: *IEEE Cloud Computing* 3 (2016), Nr. 4, S. 66–73
- [4] FELDHORST, Sascha ; MASOUDENIJAD, Mojtaba ; HOMPEL, Michael ten ; FINK, Gernot A.: Motion Classification for Analyzing the Order Picking Process using Mobile Sensors - General Concepts, Case Studies and Empirical Evaluation. In: *Proceedings of the 5th International Conference on Pattern Recognition Applications and Methods* : SCITEPRESS - Science and Technology Publications, 2016, S. 706–713
- [5] ROTHER, Mike ; SHOOK, John: *Learning to see: value stream mapping to add value and eliminate muda* : Lean enterprise institute, 2003
- [6] QU, Ting ; THÜRER, Matthias ; WANG, Junhao ; WANG, Zongzhong ; FU, Huan ; LI, Congdong ; HUANG, George Q.: *System dynamics analysis for an Internet-of-Things-enabled production logistics system*. In: *International Journal of Production Research* 55 (2017), Nr. 9, S. 2622–2649
- [7] GRZONA, Pierre ; WEIßFLOG, Luise: Evaluation of process mining for a typical plant planning task. In: *Průmyslové inženýrství 2023* : University of West Bohemia, 2023, S. 134–146
- [8] HARRIS, Malcolm Anthony ; KACZMAREK, Sascha ; FELDHORST, Sascha: Sensoren und Algorithmen für die automatische Analyse von manuellen Prozessen in der Logistik 4.0. In: HOMPEL, Michael ten (Hrsg.): *Logistik : Mit 231 Abbildungen und 10 Tabellen*. 3. Auflage. Berlin, Germany : Springer Vieweg, 2020 (Springer reference, Band 3), S. 461–475
- [9] WILSKY, Philipp ; CLAUSNITZER, Yvonne ; RIEDEL, Ralph: *Dimensionierung von Lokalisierungsankern in Produktionssystemen*. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 119 (2024), 7-8, S. 543–547. URL <https://www.degruyter.com/document/doi/10.1515/zwf-2024-1101/html>
- [10] HOFMANN, Constantin ; PATSCHKOWSKI, Christopher ; HAEFNER, Benjamin ; LANZA, Gisela: *Machine Learning Based Activity Recognition To Identify Wasteful Activities In Production*. In: *Procedia Manufacturing* 45 (2020), S. 171–176
- [11] BAUER, Wilhelm ; BRAUNREUTHER, Stefan ; BERGER, Christoph ; BRANDT, Peter ; BREITER, Stephan ; DIRZUS, Dagmar ; EICKHOFF, Gisela ; GLOY, Yves ; JESKE, Tim ; KORGE, Axel ; KURZ, Constanze ; SCHLUND, Sebastian ; SCHWEDE, Christian ; SCHWEPPE, Kai ; STRÖLIN, Tobias ; URBAS, Leon ; VEERKAMP-WALZ, Andrea ; WISCHMANN, Steffen ; ZIEGLER, Jens: *VDI-Statusreport: Arbeitswelt Industrie 4.0*
- [12] APPELHANS, Hendrik ; FELDMANN, Carsten ; BORGMANN, Christopher: Sensor-Based Analysis of Manual Processes in Production and Logistics: Motion-Mining versus Lean Tools. In: FREITAG, Michael; KINRA, Aseem; KOTZAB, Herbert; MEGOW, Nicole (Hrsg.): *Dynamics in Logistics*. Cham : Springer Nature Switzerland, 2024 (Lecture Notes in Logistics), S. 235–248
- [13] KIM, Eunju ; HELAL, Sumi ; COOK, Diane: *Human Activity Recognition and Pattern Discovery*. In: *IEEE pervasive computing* 9 (2010), Nr. 1, S. 48
- [14] MEKRUKSAVANICH, Sakorn ; JITPATTANAKUL, Anuchit: A Comparative Study of Deep Learning Robustness for Sensor-based Human Activity Recognition. In: *2023 46th International Conference on Telecommunications and Signal Processing (TSP) : IEEE*, 2023, S. 87–90
- [15] MEKRUKSAVANICH, Sakorn ; JITPATTANAKUL, Anuchit: Classification of Gait Pattern with Wearable Sensing Data. In: *2019 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT-NCON) : IEEE*, 2019, S. 137–141
- [16] YANG, Jaeyoung ; LEE, Joonwhan ; CHOI, Joongmin: *Activity Recognition Based on RFID Object Usage for Smart Mobile Devices*. In: *Journal of Computer Science and Technology* 26 (2011), Nr. 2, S. 239–246
- [17] HUSSAIN, Zawar ; SHENG, Quan Z. ; ZHANG, Wei Emma: *A review and categorization of techniques on device-free human activity recognition*. In: *Journal of Network and Computer Applications* 167 (2020), S. 102738

- [18] ROHRIG, Christof ; KUNEMUND, Frank: Estimation of position and orientation of mobile systems in a wireless LAN. In: *2007 46th IEEE Conference on Decision and Control* : IEEE, 2007
- [19] HERMSDORF, Heike ; HOFMANN, Norman ; KEIL, Albrecht: Bewertung digital erfasster Bewegungen mit Dynamicus. In: BULLINGER-HOFFMANN, Angelika C.; MÜHLSTEDT, Jens (Hrsg.): *Homo Sapiens Digitalis - Virtuelle Ergonomie und digitale Menschmodelle*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2016, S. 329–336
- [20] AL-ZUBAIDI, Salam Qaddoori Dawood ; COLI, Elena ; FANTONI, Gualtiero: *Automating Production Process Data Acquisition Towards Spaghetti Chart 4.0*. In: *International Journal of Industrial Engineering and Management* 13 (2022), Nr. 3, S. 145–158
- [21] CHEN, Liming ; HOEY, J. ; NUGENT, C. D. ; COOK, D. J. ; YU, Zhiwen: *Sensor-Based Activity Recognition*. In: *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 42 (2012), Nr. 6, S. 790–808
- [22] LARA, Oscar D. ; LABRADOR, Miguel A.: *A Survey on Human Activity Recognition using Wearable Sensors*. In: *IEEE Communications Surveys & Tutorials* 15 (2013), Nr. 3, S. 1192–1209
- [23] FORKAN, Abdur Rahim Mohammad ; MONTORI, Federico ; GEORGAKOPOULOS, Dimitrios ; JAYARAMAN, Prem Prakash ; YAVARI, Ali ; MORSHED, Ahsan: An Industrial IoT Solution for Evaluating Workers' Performance Via Activity Recognition. In: *2019 IEEE 39th International Conference on Distributed Computing Systems (ICDCS)* : IEEE, 2019, S. 1393–1403
- [24] MEHRIZI, Rahil ; PENG, Xi ; XU, Xu ; ZHANG, Shaoting ; METAXAS, Dimitris ; LI, Kang: *A computer vision based method for 3D posture estimation of symmetrical lifting*. In: *Journal of biomechanics* 69 (2018), S. 40–46
- [25] WEIßFLOG, Luise ; GRZONA, Pierre ; THÜRER, Matthias: Balancing the Three-Legged Stool of Learning Factories, Bd. 1060. In: THIEDE, Sebastian; LUTTERS, Eric (Hrsg.): *Learning Factories of the Future*. Cham : Springer Nature Switzerland, 2024 (Lecture Notes in Networks and Systems), S. 67–74

Dipl.-Ing. Pierre Grzona, wissenschaftlicher Mitarbeiter an der Professur Fabrikplanung und Intralogistik mit den Arbeitsschwerpunkten in den Methoden und Modellen der digitalen Fabrik sowie der Intralogistik.

Keyur Raval, BSc, studentische Hilfskraft an der Professur Fabrikplanung und Intralogistik, beschäftigt sich im Rahmen seiner Masterarbeit mit dem Einsatz von datengetriebenen Analysemethoden zur Erfassung logistischer Kennzahlen.

Philipp Wilsky, MSc, wissenschaftlicher Mitarbeiter an der Professur Fabrikplanung und Intralogistik mit den Arbeitsschwerpunkten in der Lehrkoordination und Lokalisierungslösungen in Produktionssystemen.

Prof. Dr. Matthias Thüerer, Lehrstuhlinhaber der Professur Fabrikplanung und Intralogistik an der Technischen Universität Chemnitz.

Adresse: Professur Fabrikplanung und Intralogistik,
Technische Universität Chemnitz, Erfenschlager Str. 73,
09125 Chemnitz, Germany,
Phone: +49 371 531-36495,
E-Mail: pierre.grzona@mb.tu-chemnitz.de