

Schlussbericht vom 14.07.2025

zum IGF-Vorhaben Pakur - 01IF22815N

Thema

KI-basierte Zählung, Klassifikation und Prüfung palettierter Pakete bei der Warenannahme und Inventur mittels optischer Verfahren auf mobilen Endgeräten

Berichtszeitraum

01.04.2023 bis 31.03.2025

Forschungsvereinigung

Bundesvereinigung Logistik (BVL) e.V.

Forschungseinrichtung(en)

BIBA - Bremer Institut für Produktion und Logistik GmbH

Hochschulring 20

28359 Bremen

Inhaltsverzeichnis

1	Durchgeführte Arbeiten und Ergebnisse	3
1.1	Arbeitspaket 1: Anforderungsanalyse	3
1.2	Arbeitspaket 2: Konzeption	4
1.3	Arbeitspaket 3: Datensatz- & Benchmark Generierung	5
1.4	Arbeitspaket 4: Entwicklung der Algorithmen	9
1.5	Arbeitspaket 5: Entwicklung der Demo-App	13
1.6	Arbeitspaket 6: Integration	15
1.7	Arbeitspaket 7: Gesamt-Evaluation	15
1.8	Arbeitspaket 8: Projektmanagement	16
2	Verwendung der Zuwendung	17
3	Notwendigkeit und Angemessenheit der geleisteten Arbeit	17
4	Darstellung des wissenschaftlich-technischen und wirtschaftlichen Nutzens der erzielten Ergebnisse insbesondere für KMU sowie ihres innovativen Beitrags und ihrer industriellen Anwendungsmöglichkeiten	17
5	Wissenstransfer in die Wirtschaft	18
6	Durchgeführte Transfermaßnahmen	19
7	Geplante spezifische Transfermaßnahmen nach der Projektlaufzeit	19
8	Literaturverzeichnis	20

1 Durchgeführte Arbeiten und Ergebnisse

1.1 Zusammenfassung

Das Projekt PAKUR hat in mehreren Arbeitspaketen erfolgreich eine Lösung zur Paketerkennung und -zählung auf palettierter Ware entwickelt. Zunächst wurden umfassende Anforderungskataloge für Bilddatensätze, Benchmarks, Algorithmen, Demo-Apps und Evaluation erstellt. Darauf aufbauend wurden Konzepte zur Generierung synthetischer und realer Bilddatensätze sowie eines praxisnahen Benchmarks entwickelt. Ein modular aufgebauter Algorithmus basierend auf modernen Methoden wie YOLOv8, Transformer-basiertem OCR (Donut Model) und Segment-Anything Model wurde implementiert und getestet. Parallel entstanden zwei Prototypen einer Android Floor-App und eines browserbasierten Planer-Dashboards, die mit den Backend-Services via RestAPI integriert wurden. Obwohl ein umfassender Feldtest im Projektzeitraum nicht realisiert werden konnte, lieferte ein prototypischer Testlauf wertvolle Erkenntnisse zu Schwachstellen. Das Projekt wurde koordiniert, dokumentiert und durch zielgerichtete Dissemination der Ergebnisse in Fachkreisen begleitet. Insgesamt entstand eine funktionale, modulare, und praxisorientierte Gesamtlösung zur automatisierten Paketerkennung auf Paletten.

Im Rahmen des Projekts „Pakur“ wurden folgenden Arbeitspakete bearbeitet:

- Arbeitspaket 1: Anforderungsanalyse
- Arbeitspaket 2: Konzeption
- Arbeitspaket 3: Datensatz- & Benchmark Generierung
- Arbeitspaket 4: Entwicklung der Algorithmen
- Arbeitspaket 5: Entwicklung der Demo-App
- Arbeitspaket 6: Integration
- Arbeitspaket 7: Gesamt-Evaluation
- Arbeitspaket 8: Projektmanagement

Die einzelnen Arbeitspakete werden im Folgenden vorgestellt.

1.2 Arbeitspaket 1: Anforderungsanalyse

Ziele

Ziel des Arbeitspakets ist die Ermittlung der diversen Anforderungen für das Vorhaben, die sich in fünf Unterkategorien einteilen lassen, welche im Folgenden beschrieben werden.

Durchgeführte Arbeiten

1. **Ermittlung der Anforderungen an den benötigten Bild-Datensatz:** Für den Trainingsdatensatz wurden Spezifikationen von aktuellen Smartphone Kameras für die Bildqualität und Auflösung abgeleitet. Für die Variation des Betrachtungswinkels, der Entfernung zur Palette, Lichtverhältnisse, Variationen der Palette und ihrer Beladung wurde ein Konzept erarbeitet, dass eine kontinuierliche Bilderzeugung für das Training vorsieht, die dabei die Parameter aus einer begrenzten Verteilung zieht. Ein Testdatensatz, bei dem die Verteilungen deutlich erweitert werden und somit Bilder entstehen, bei der eine Einwandfreie Detektion nicht immer möglich ist. Dies geschieht durch möglicherweise unmögliche Kombinationen z.B. aus

Betrachtungswinkel und Lichtverhältnissen. Dieser Datensatz dient der Spezifikation der Systemgrenzen. Für das Training wurde der Anteil der synthetischen Daten auf 100% gesetzt.

2. **Ermittlung der Anforderungen an den Benchmark für Paketerkennung und –Zählung:** Die Form des Benchmarks soll auf dem MS COCO Datensatz/-format aufbauen. Als Anforderungen an den Benchmark wurden Ladungs- und Palettenvarianten aufgestellt. Dabei werden die Ladungsträgerart, das optische Erscheinungsbild, sowie die Ladungsvarianten (bspw. grau/braune Pakete, hochglanzbedruckte Kartons oder Säcke) berücksichtigt.

3. **Ermittlung der Anforderungen an den Algorithmus:** Nach Experten-Interviews und Literaturrecherche wurde pytorch als Softwareframework festgelegt und der Open API Standard für die Schnittstelle ausgewählt, welcher über RestAPI umgesetzt werden soll. Beim Erstellen des Anforderungskatalogs wurde festgestellt, dass der Algorithmus feingliedriger aufgeteilt werden muss, weil es mehrere hintereinander auftretende und einzeln zu lösende Teilprobleme gibt. Das Ergebnis ist eine Bildverarbeitungspipeline, die aus mehreren Algorithmen steht.

4. **Ermittlung der Anforderungen an die Demo-App:** Auf Grundlage von Experteninterviews wurde entschieden eine Android App sowie ein betriebssystemunabhängiges Browser-Dashboard zu entwickeln. Auch hier wurden die Verwendung von RestAPI Schnittstellen vereinbart. Die Anforderung an die Benutzbarkeit der App wurde mit Experten erhoben.

5. **Ermittlung der Anforderungen an die finale Evaluation:** Die finale Evaluation soll in Feldtests bei Mitgliedern des PAs erfolgen, um Schwachstellen aufzuzeigen, die behoben werden müssen, um einen Transfer in die Praxis bzw. eine Integration in den realen Prozess zu gewährleisten. Aufgrund der Individualität der Betriebe, müssen noch vor den einzelnen Feldtests genaue Details der Anforderungen per Experteninterview ermittelt werden, damit auch sichergestellt ist, dass diese Anforderung überprüfbar ist.

Erzielte Ergebnisse

1. Anforderung Bilddatensatz: Anforderungskatalog für die synthetischen Trainingsdaten und die synthetische sowie reale Testdaten, um ein robustes Training zu ermöglichen.
2. Anforderung Benchmark: Anforderungskatalog für den Benchmarkdatensatz, um eine einfache Verbreitung sowie eine umfassende Evaluierung zu ermöglichen.
3. Anforderung Algorithmus: Anforderungskatalog für die unterschiedlichen Algorithmen, um die Pipeline bestmöglich umzusetzen.
4. Anforderung Demo-App: Anforderungskatalog für die App, um die Funktionalitäten, Eigenschaften und Leistungsmerkmale der Anwendung festzuhalten.
5. Anforderung finale Evaluation: Anforderungskatalog für die Grobumsetzung.

1.3 Arbeitspaket 2: Konzeption

Ziele

Ziel des Arbeitspakets ist die Formulierung von umsetzbaren Konzepten für die wesentlichen Arbeitsschritte, anhand derer dann die Realisierung erfolgt.

Durchgeführte Arbeiten

1. **Konzeption der Generierung des Bild-Datensatzes:** Es wurde festgelegt, welche Hardware (Smartphone) für die Aufnahmen angeschafft wird, welche Software (Nvidia Omniverse) für die Erstellung der synthetischen Daten verwendet wird und wie diese Erstellung durchgeführt wird. Dabei wurde der Fokus auf Kontrollierbarkeit des Outputs gelegt. Das wird über Variablen für jegliches Erscheinungsbild (z.B. Betrachtungswinkel, Helligkeit, Drehung, Entfernung, Paketgröße in allen Dimensionen, Packmuster, Packhöhe) ermöglicht. Das Nutzen von Zufallsvariablen aus entsprechen parametrisierten Verteilungen ermöglicht dadurch auch das Erstellen von beliebig vielen Testdaten.
2. **Konzeption des Benchmarks:** Der Benchmark wurde in mehrere Schwierigkeiten unterteilt: Sortenrein mit vollständigem Abschluss, sortenrein mit möglichen fehlenden Elementen in der obersten Schicht, und nicht sortenreine Beladungen. Zusätzlich wurden für das Abschneiden auf dem Datensatz unterschiedliche Bewertungskriterien eingeführt. Dabei wird die Anzahl an ermittelten Einheiten mit den realen Daten verglichen. Feingliedriger kann das auch auf Schichtebene passieren.
3. **Konzeption des Algorithmus:** Es wurde ein Vorgehen festgelegt um die einzelnen Algorithmen in der Pipeline zu entwickeln. Dabei wurden vor allem Fokus auf die Randfälle der einzelnen Probleme gelegt.
4. **Konzeption der Demo-App:** Es wurde festgelegt, welche Features in der Demo-App vorkommen sollen. Dabei wurde berücksichtigt, dass Mitarbeitende auf der Fläche andere Aufgaben und somit andere Anforderungen an die Anwendung haben, als ein Mitarbeitende aus der Planung. Deswegen wurden zwei Apps konzipiert. Erstens eine App fürs Smartphone mit unter anderem den Funktionen Aufträge anzusehen und abzuarbeiten, sowie Aufträge zu bearbeiten (sprich Fotos für die Auswertung zu machen). Zweitens eine Planungs-App, wo mit dem Warenwirtschaftssystem interagiert werden kann, Aufträge angelegt und verwaltet werden können.
5. **Konzeption der finalen Evaluation:** Es wurde ein Konzept für die Evaluation skizziert. Ein detailliertes Vorgehen wurde an die Prozesse der Mitglieder des PAs, die sich bereit erklärt haben, dass eine Evaluation bei Ihnen durchgeführt werden kann, erarbeitet.

Erzielte Ergebnisse

1. Konzeption der Generierung des Bild-Datensatzes: Pflichtenheft für das Konzept für die Generierung des Datensatzes.
2. Konzeption des Benchmarks: Pflichtenheft für das Konzept für die Generierung des Benchmarks.
3. Konzeption des Algorithmus: Pflichtenheft für das Konzept für die Erstellung der Algorithmen der Pipeline.
4. Konzeption der Demo-App: Pflichtenheft für das Konzept für die Demo-Apps.
5. Konzeption der finalen Evaluation: Grobkonzept für die Feldtests.

1.4 Arbeitspaket 3: Datensatz- & Benchmark Generierung

Ziele

Ziel ist die Generierung eines Bild-Datensatzes, welcher für die spätere Algorithmen-Entwicklung geeignet ist, sowie die Entwicklung eines öffentlichen Benchmarks basierend auf einer Teilmenge des Datensatzes,

welcher die Vergleichbarkeit von Algorithmen ermöglicht, die sich der Problemstellung der Paketzählung und -erkennung von palettierter Ware widmen.

Durchgeführte Arbeiten

- Datensatz-Generierung mittels Fotografie:** Erste Bilder wurden in der Forschungshalle aufgenommen, aber der Prozess hat sich, vor allem hinsichtlich der Variation und Datenannotation als komplex herausgestellt. Die Datenannotation wurde beschleunigt durch semi-automatisierte Verfahren basieren auf einer Paletten Erkennung und dem Segment-Anything (SAM)-Modell. (s. Abbildung 1: Durch die Nutzung des Segment-Anything (SAM) Modells lässt sich die aufwändige Annotation einzelner Pakete im Idealfall durch einen einzigen Klick erledigen. Hierfür werden verschiedene Varianten (SAM und MobileSAM) getestet. Grün: Paketmasken die mit einem Klick erstellt wurden. Abbildung 1). Der Bedarf, die Daten mit realen Daten aus den Lägern der Partner zu erweitern, wurde festgestellt. Sortenunreinheit, ungleichmäßige Muster, Verpackung (Folie, Bänder, Eckenschützer,...), vereinzelt Pakete und unzureichende Fotos sind aufgedeckte, mögliche Fehlerquellen. Insgesamt wurden 9747 Aufnahmen mit entsprechenden Kontextinformationen (Packmuster, Paketgrößen, Anzahl) zu einem Gesamtdatensatz zusammengefasst. Die aufgenommenen Bilder wurden manuell gelabelt, wobei Paketanzahl, -position und Paketart annotiert wurden. Ein Beispielbild ist in Abbildung 2 zu sehen.
- Synthetische Datensatz-Generierung:** Für das Erstellen der synthetischen Daten sowie ihre automatische Labelgenerierung wurden zwei Ansätze erprobt. Es wurden 3D Objekte per Nvidia Omniverse (s. Abbildung 3) und per Unity (s. Abbildung 4) erzeugt, angeordnet, fotografiert und gelabelt. Aufgrund der fotorealistischeren Bilder, der Bereitstellung von industrietauglichen optischen Assets, der einfacheren Erzeugung von großen Datenmengen über Nvidia Omnivers Replicator und der Möglichkeit der automatischen Integration in eine Machine Learning Pipeline wurden die Beispieldaten per Nvidia Omniverse erzeugt. (s. Abbildung 5). Das Labeling dieser Daten erfolgt automatisiert direkt aus den 3D-Szenen. Durch die automatisierte Erzeugung der Daten wurden immer neue Bilder für das Training erzeugt. Die Bilder decken unterschiedliche Perspektiven, Abstände, Beleuchtungssituationen, Paketanzahl, -position und -arten, sowie unterschiedliche Packmuster ab.
- Erstellung des Benchmarks:** Nachdem Erstellen erster Metriken wurden festgestellt, dass es eine Einteilung in Fehlerarten geben muss. Eine Abweichung in der Paketanzahl zwischen IST und SOLL ist immer ein Fehler, aber die Schwere des Fehlers muss gesondert bewertet werden. Dabei können die falschen Paletten in den Fokus gekommen sein, es wurden Pakete oder das Packmuster falsch erkannt. Jede einzelne Fehlerart muss nochmal einzeln aufgeschlüsselt werden. Als Teilprobleme wurden identifiziert: Erkennung von Sortenreinheit, ungleichmäßigen Muster, Verdeckung durch Verpackung (Folie, Bänder, ...), fehlerhafte Anzahl auf den jeweiligen Achsen bzw. insgesamt, Erkennung von vereinzelt Paketen und Objekten, die nicht zur Ladung gehören. Auf Basis des kombinierten Datensatzes wurde eine repräsentative Teilmenge von 1000 Bildern ausgewählt, die typische Herausforderungen der Paketerkennung (z. B. Überlappung, unterschiedliche Perspektiven, gemischte Palettierung) abbildet. Zur Auswahl wurden auch Zwischenergebnisse aus der Algorithmus-Entwicklung (AP4) herangezogen, insbesondere hinsichtlich Fehlklassifikationen. Der Benchmark wurde mit einer Beschreibung der unterschiedlichen Metriken für die einzelnen Fehlerarten versehen. Dabei wurde vorerst nur die Fehlerart Packmuster also Anzahl der Pakete auf den jeweiligen Achsen eingefügt. Eine Veröffentlichung über eine geeignete, öffentliche Plattform wird im Anschluss an das Projekt angestrebt.

Erzielte Ergebnisse

1. Datensatz-Generierung mittels Fotografie: Ein umfassender, gelabelter Bild-Datensatz mit realen erzeugten Bildern palettierter Ware.
2. Synthetische Datensatz-Generierung: Generator für das Erstellen von synthetischen Daten in Nvidia Omniverse. Ein damit erstellter Datensatz von synthetischen Bildern.
3. Erstellung des Benchmarks: Ein Benchmark, der typische Schwierigkeiten der Anwendung praxisnah abbildet und eine vergleichbare Bewertung unterschiedlicher Ansätze erlaubt.




Abbildung 1: Durch die Nutzung des Segment-Anything (SAM) Modells lässt sich die aufwändige Annotation einzelner Pakete im Idealfall durch einen einzigen Klick erledigen. Hierfür wurde verschiedene Varianten (SAM und MobileSAM) getestet. Grün: Paketmasken die mit einem Klick erstellt wurden.



Abbildung 2: Beispielbild aus dem 9747 starkem Realbild-Datensatz.



Abbildung 3: Nvidia Omniverse: Links: erste Paletten mit Zuladung. Rechts: Objekte nach ID eingefärbt.




Abbildung 4: Zufällig erzeugte Objekte in Unity erzeugt. Können später über ein normales Foto drübergelegt werden.



Abbildung 5: Generiertes Beispielbild aus dem synthetischen Datensatz.

1.5 Arbeitspaket 4: Entwicklung der Algorithmen

Ziele

Die Entwicklung einer oder mehrerer Algorithmen für die einzelnen Arbeitsschritte der beschriebenen Pipeline. Diese soll dann in der Lage sein, auf Paletten eine Einheitenkennung sowie -Zählung durchzuführen. Diese Pipeline stellt das Back-End dar.

Durchgeführte Arbeiten

1. **Entwicklung der Algorithmen:** Nach dem Testen mehrerer Verfahren und Herangehensweisen wurde der gesamte Vorgang in einzelne Schritte runtergebrochen und über einzelnen Algorithmen abgebildet (s. Abbildung 6). Durch separate Dienste wurden die Algorithmen bausteinartig integriert, in Containern gekapselt und über eine RestAPI zur Verfügung gestellt. Die Labelerkennung wurde über das Donut Model bereitgestellt (s. Abbildung 7). Das Donut Model ist ein potenter Transformer für kontextbasierte Optical Character Recognition (OCR) und wurde hier vor allem dafür verwendet, um von den Labels die Kontextinformationen der Palette zu extrahieren. Diese Informationen stehen dann für einen Vergleich mit dem Warenwirtschaftssystem bzw. mit den vom optischen Verfahren ermittelten Ladungsmengen zur Verfügung zu stellen. Über die Partner wurde eine Ortung der mobilen Endgeräte als nützliches Feature identifiziert. Diese wurde über den Projektkinhalt hinaus über eine Schnittstelle bereitgestellt. Dadurch ist auch eine Verortung der Palette und ein Abgleich über eine Standortplanung möglich. Beispielhaft wurde dieses Feature in der Forschungshalle des Instituts per Wifi Round Trip Time und Ultra Wide Band integriert und getestet. Für die Palettenerkennung wurde ein eigenes Netz auf Basis des SDG Pallet Models entwickelt. Dieses identifiziert alle sichtbaren Paletten in einem Bild und ermittelt die acht Eckpunkte je Palette. Eine Darstellung davon ist in Abbildung 8 zu sehen. Da mehrere Paletten je Bild erkannt werden können, wird für das weitere Vorgehen die Palette weiterverwendet, die dem Bildmittelpunkt am nächsten ist. Zusätzlich wird per Segment Anything Model die Ladung der Palette segmentiert. Dafür wird davon ausgegangen, dass die Mitte der Palette von ihrer Ladung verdeckt wird. Dadurch wird eine Segmentierungsmaske erstellt, welche später für die Identifizierung der Pakete von Interesse verwendet wird. Eine Visualisierung ist in Abbildung 9 zu sehen.

Die Paketerkennung wurde per YOLO v8 implementiert. Eine Repräsentation ist in Abbildung 10 zu sehen. Generell werden alle Pakete im Bild erkannt. Alle Pakete, die Überlappung mit der Segmentierungsmaske haben, werden als Pakete von Interesse identifiziert. Von diesen Paketen werden dann wie bei dem SDG Palett Model 3D Boundingboxen über ein dafür entwickeltes EstimNet erstellt. Die Packmustererkennung erfolgt dann über eine Umwandlung in ein Optimierungsproblem. Dabei werden die 3D Boundingboxen in ein Koordinatensystem der Palette transformiert, damit die optische Verzerrung der Kamera keinen Einfluss hat. Die erkannten Pakete werden in ihren Abmessungen im gleichen Muster drei dimensional angeordnet. Freies Volumen wird über gleiche Packart versucht aufzufüllen. Hat dieses Optimierungsproblem eine eindeutige Lösung, so wird diese als das entsprechende Packmuster angenommen. Mit dem ermittelten Packmuster können dann Anzahl der Ladungseinheiten auf dem Ladungsträger ermittelt werden.

2. **Testen der Algorithmen:** Getestet wurde auf dem Datensatz aus AP3. Wobei die Realdaten aufgrund der fehlenden Groundtruth nur für Packmustern- und Anzahltests herangezogen wurden. Die synthetischen Daten werden prozedural erzeugt und der Benchmark Datensatz wurde explizit nicht zum Trainieren verwendet, um keinen Bias in den Ergebnissen zu haben.

3. **Testen der Performance der Algorithmen:** Die Palettenerkennung liefert robuste Ergebnisse. Jede in der Bildmitte vorhandene Palette wird erkannt. Sind vordere Eckpunkte der Palette verdeckt, so funktioniert eine Detektion nicht mehr. Das ist bewusst so eingestellt, um keine false positive Paletten, also Paletten, die es gar nicht gibt und die trotzdem fälschlicherweise detektiert werden, zu erhalten. Es werden nicht immer alle acht Eckpunkte Pixelgenau gesetzt und auch eine falsche Orientierung im Raum von wenigen Grad ist in ungefähr 50% der Fälle der Fall. In Abbildung 8 ist genau so ein Fall dargestellt. Eine exakte optische Verortung ist für diesen Anwendungsfall nicht notwendig, weshalb keine weitere Optimierung vorgenommen wurde. Um die Güte der Segmentierungsmaske zu bestimmen wurde die Intersection over Union mit 50% Überlappung verwendet, welche eine der gängigsten Metriken für die Segmentierung auf Pixelebene ist. Bei der Paketerkennung ist die Genauigkeit abhängig vom Konfidenzwert, also ab welchem Sicherheitsgrenzwert das Model ein Packet als Packet erkennt. Wird dieser Wert zu klein gewählt, erhöht sich die Zahl der fälschlicherweise als Packte erkannten Objekte. Entsprechend umgekehrt verhält es sich, wenn man den Wert zu groß wählt. Welche Konfidenzen das Model bei den einzelnen Packten hat, ist in Abbildung 10 zu sehen. Die durch das EstimNet erzeugten Eckpunkte wurden dann mit einem angepasstem Mean Square Error (MSE) bewertet. Dabei wurden die acht Eckpunkte jeweils den Groundtruth Eckpunkten zugeordnet, so dass die Summe der acht MSE minimiert wird. Bei dem anschließenden Optimierungsproblem wurde die Lösung nur noch mit der Groundtruth verglichen und wenn die übereinstimmt, als korrekt deklariert. Generell gibt es hier noch Optimierungsbedarf und der User sollte noch einmal zur Validierung herangezogen werden. Vor allem leere Paletten mit Paketen im Hintergrund ist noch ein Problem.

4. **Generelle Software-Tests:** Alle Teile der Pipeline wurden als Dienst per RestAPI Schnittstellen zur Verfügung gestellt. Durch diese Architektur konnten einzelne Fehler in der Formatierung, den Ausgaben und den einzelnen Diensten identifiziert und behoben werden.

Erzielte Ergebnisse

1. Entwicklung der Algorithmen: Algorithmen für die jeweiligen Teilprobleme.
2. Testen der Algorithmen: Tests haben die Schwachstellen, aber auch die Situationen, in denen der Vorgang funktioniert, aufgezeigt.

3. Testen der Performance der Algorithmen: Die Dienste schneiden für sich gesehen gut ab, aber das Fortpflanzen von Fehlern ist kritisch zu sehen.
4. Generelle Software-Tests: Funktionsfähige Pipeline.




Abbildung 6: Aufschlüsselung der einzelnen Dienste, die für die Auswertung des Fotos nötig sind.




Abbildung 7: Aufnahmen während der Nutzung der App für die Labelerkennung. Der Scanner kann auch handschriftliche Eintragungen erkennen.




Abbildung 8: Paletten Erkennung über SDG Pallet Model.



Abbildung 9: Ladungssegmentierung über SAM. Der Stern repräsentiert die Mitte der Palette, was als Start für die Segmentierungsmaske verwendet wird. Die abschließende Segmentierungsmaske wurde über die blaue Einfärbung visualisiert.



Abbildung 10: Paketerkennung über YOLOv8.

1.6 Arbeitspaket 5: Entwicklung der Demo-App

Ziele

Entwicklung einer Demonstrations-Applikation, welches das Front-End darstellt.

Durchgeführte Arbeiten

1. **Entwicklung der Demo-App:** Es wurden die zwei Prototypen der Planer-App und Floor-App erweitert. Eine Integration des Warenwirtschaftssystems wurde durch die Integration einer Datenbank und das Nutzen der RestAPI umgesetzt. Die Planer-App (s. Abbildung 11) ist ein Browser basiertes Programm die auf der Datenbank aufsetzt. Damit können neue Aufträge angelegt, zugordnet, editiert und gelöscht werden. Außerdem sind auf einer Kartenansicht alle aktuellen Aufträge zu sehen. Dabei werden einzelne Aufträge zwischen Wareneingang, -Ausgang und Inventur unterschieden und auf einer Kartenansicht angezeigt. Mobile Endgeräte mit der Floor-App werden verortet und Aufträge können so einfacher örtlich nahen mobile Endgeräte zugeordnet werden. Die Floor-App (s. Abbildung 12) bietet eine Möglichkeit dem User zugeordnete Aufträge anzusehen, zu bearbeiten und abzuarbeiten. Die Aufträge enthalten alle relevanten Informationen, die vorher aus dem Warenwirtschaftssystem geholt wurden. Auf der Kartenansicht wird der hinterlegte Ort angezeigt. Dort kann dann der Auftrag bearbeitet werden indem ein Foto von der Palette gemacht wird. Dieses Foto durchläuft dann die einzelnen Dienste, die in AP 4 detailliert dargestellt wurden. Das Ergebnis wird dann

automatisch mit dem Eintrag aus dem Warenwirtschaftssystem verglichen und bei Diskrepanzen wird der Nutzer informiert.

2. **Testen der Demo-App:** Es wurden Nutzbarkeitstests durchgeführt und durch mehrere Feedback-loops entsprechende Bugs behoben und Features eingebaut.

Erzielte Ergebnisse

1. Entwicklung der Demo-App: Floor-App und Planer-App jeweils als Prototyp mit den rudimentären Funktionen. Insbesondere die Floor-App mit allen API Call Möglichkeiten, um alle Dienste anzusprechen.
2. Testen der Demo-App: Prototypische Floor-App.




Abbildung 11: Dashboard der Planer-App mit sichtbaren Aufträgen. Wareneingang (Einkaufswagen), Warenausgang (Pfeil), Inventur (Lagerhalle) und Standort (oranger Kreis).




Abbildung 12: Ansichten aus der Floor-App. Links: Anmeldemaske. Mitte-Links: Dem Nutzer zugeordnete Aufträge. Mitte-Rechts: Fotografie Screen. Rechts: Anzeigen vom ausgewerteten Bild.

1.7 Arbeitspaket 6: Integration

Ziele

Zusammenführung des Back-Ends (AP4 Paketerkennung) und Front-Ends (AP5 Demo-App) zu einer ganzheitlichen, einsetzbaren Lösung.

Durchgeführte Arbeiten

1. **Funktionstests:** Jeder einzelne Schritt wurde als Dienst, der über einen API-Call erreichbar ist, integriert. Dadurch kann das Front-End einfach auf alles zugreifen. Zusätzlich besteht die Freiheit, dass die Algorithmen über die Dienste auch ohne die App und unabhängig voneinander nutzbar sind. Das Struktogramm des Back-Ends ist in Abbildung 13 zu sehen.
2. **Erprobung der Demo-App:** Mit der Demo-App können alle eingebundenen Dienste erprobt werden. Auftretende Schwierigkeiten konnten dienstspezifisch identifiziert und behoben werden ohne, dass die App verändert werden muss. Dieses Bausteinprinzip ermöglichte eine effiziente Weiterentwicklung des Prozesses. Dies führte zu einem stetigen Testen der App und somit zu einem Aufzeigen der Fehler.

Erzielte Ergebnisse

1. Lauffähige und einsatzbereite Demo-App mit Paketerkennungsalgorithmus.
2. Möglichkeit quantitative die App und die Dienste zu testen.




Abbildung 13: Struktogramm des Back-Ends und der einzelnen Dienste.

1.8 Arbeitspaket 7: Gesamt-Evaluation

Ziele

Finale Evaluation des Gesamtsystems, bestehend aus der App und den Algorithmen.

Durchgeführte Arbeiten

1. **Durchführung von Labortests:** Die Labortests des Gesamtsystems, also insbesondere der Demo-Apps und der einzelnen Dienste wurden durchgeführt. Eine Umfrage zur Bedienerfreundlichkeit wurde erstellt. Die Labortests haben diverse Optimierungsmöglichkeiten des Algorithmus aufgezeigt.

2. **Durchführung der Feldtests:** Ein Feldtest bei den Partnern des PAs konnte während der Projektlaufzeit nicht durchgeführt werden. Die vom BIBA beantragte Laufzeitverlängerung konnte administrativ nicht realisiert werden.

Erzielte Ergebnisse

1. Liste aufgedeckter Schwachstellen durch den Labortests.
2. Ablaufplan der Feldtests

1.9 Arbeitspaket 8: Projektmanagement

Ziele

Koordinierung der einzelnen Arbeitspakete sowie die Organisation der Treffen mit dem projektbegleitenden Ausschuss, sowie Fertigstellung von Zwischen- und Abschlussberichten. Auf der Forschungsseite die Veröffentlichung von Zwischen- und Endergebnissen sowie der Besuch von wissenschaftlichen Fachkonferenzen, um Öffentlichkeitsarbeit für das Projekt zu leisten und Feedback und Input von Fachkollegen einzuholen.

Durchgeführte Arbeiten

1. **Projektkoordination:** Im Rahmen des Arbeitspakets Projektmanagement wurden alle administrativen und koordinativen Aufgaben ordnungsgemäß durchgeführt. Die Projektkoordination stellte die Einhaltung des Zeit- und Maßnahmenplans sicher und übernahm die Kommunikation mit der BVL sowie der Mitglieder aus dem projektbegleitenden Ausschuss.
2. **Berichtswesen:** Zwischen- und Abschlussberichte wurden termingerecht erstellt und eingereicht.
3. **Dissemination:** Zur Verbreitung der Projektergebnisse wurden geeignete Disseminationsmaßnahmen umgesetzt, darunter Beiträge in Fachmedien sowie Informationen auf der Projektwebseite.
4. **Publikation:** Zudem wurde eine Konferenz besucht, um den Wissenstransfer mit Fachkollegen zu fördern.

Erzielte Ergebnisse

1. Einhaltung des Zeit- und Maßnahmenplans sowie reibungsloser Projektverlauf.
2. Transparente und nachvollziehbare Projektdokumentation gemäß den Anforderungen.
3. Verbreitung der Projektergebnisse in Fachkreisen und interessierten Industrieunternehmen durch Vorträge, Projektwebsite und Projektsteckbriefen.
4. Konferenzbesuch der CIRP ICME 2024.

2 Verwendung der Zuwendung

Wissenschaftlich-technisches Personal (Einzelansatz A.1 des Finanzierungsplans):

PM			
2023	2024	2025	Gesamt
10,75	14	2	26,75

Geräte (Einzelansatz B des Finanzierungsplans): -

Leistungen Dritter (Einzelansatz C des Finanzierungsplans): -

3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die im Berichtszeitraum durchgeführten Tätigkeiten entsprechend den im Forschungsantrag vorgesehenen Arbeitsschritten und sind für die Erreichung des Forschungsziels erforderlich. Die geleistete Arbeit war für die Durchführung der Arbeitsschritte erforderlich. Die Ausgaben waren für die Durchführung der geleisteten Arbeit notwendig und angemessen. Aufgrund von Personalplanung wurde die inhaltliche Bearbeitung des Projekts erst zwei Monate nach offiziellem Projektstart zum 01.04.2023 begonnen. Ein entsprechender Antrag auf Laufzeitverlängerung wurde am 17.05.2023 bewilligt, aber nicht weitergeleitet. Entsprechend fehlen die letzten Monate des Projekts.

4 Darstellung des wissenschaftlich-technischen und wirtschaftlichen Nutzens der erzielten Ergebnisse insbesondere für KMU sowie ihres innovativen Beitrags und ihrer industriellen Anwendungsmöglichkeiten

Das Projekt liefert einen Beitrag zur Automatisierung intralogistischer Prozesse, insbesondere im Bereich der Paketerkennung, -zählung und -verortung auf palettierten Ladungsträgern. Die entwickelten Komponenten, wie dem Verfahren der prozeduralen Erzeugung von synthetischen Daten, dem Benchmark Datensatz, der Erkennungsalgorithmen, sowie die Demo-Anwendung, bilden zusammen eine modulare, anwendungsnahe Lösung, die insbesondere für kleine und mittlere Unternehmen wirtschaftlich und technisch nutzbar ist.

Wissenschaftlich-technischer Nutzen:

Durch die Entwicklung einer vollständigen KI-basierten Verarbeitungspipeline für die Analyse von Palettenbildern wurde ein flexibles, erweiterbares System geschaffen, das moderne Deep-Learning-Modelle wie Transformer (Donut), Segmentierungsmodelle (SAM) und Detektionsverfahren (YOLOv8) kombiniert und mit dem neu entwickeltem EstimNet und dem Optimierer vereint. Die Architektur wurde so umgesetzt, dass alle Dienste gekapselt, standardisiert per RestAPI ansprechbar und damit leicht in bestehende Systeme integrierbar sind, was ein zentraler Aspekt für die Weiterverwendung in KMU-typischen IT-Umgebungen ist. Der öffentlich zugängliche Benchmark erlaubt die objektive Vergleichbarkeit verschiedener Ansätze zur Paketerkennung- und Zählung auf Paletten und schafft eine einheitliche Bewertungsgrundlage. Dieser schließt eine bisher fehlende Grundlage in der Forschung und Entwicklung auf diesem Gebiet. Die prozedurale Erzeugung

von synthetischen Daten ermöglicht es auch Unternehmen ohne eigenes Datenlabeling-Know-how, KI-Modelle zu trainieren oder anzupassen, was gerade für kleinere Unternehmen, die über begrenzte Mittel zur Datenerhebung und -annotation verfügen, eine wertvolle Grundlage darstellt.

Wirtschaftlicher Nutzen für KMU:

Insbesondere KMU aus Logistik, Lagerverwaltung, Fördertechnik oder Automatisierung profitieren unmittelbar von den Ergebnissen. Die entwickelte Softwarearchitektur erlaubt den gezielten Einsatz einzelner Komponenten (z. B. nur Paketerkennung oder Labelauswertung) auch in anderen Anwendungsfällen, ohne dass eine vollständige Systemmigration nötig ist. Dies reduziert Investitionskosten und senkt Einstiegshürden für digitale Prozesse. Die Möglichkeit, Lagerprozesse wie Wareneingang, Inventur oder Warenausgang durch die entwickelten mobilen und stationären Anwendungen teilautomatisiert zu unterstützen, steigert die Effizienz, reduziert manuelle Fehler und erhöht die Transparenz in Echtzeit. Die prototypische Demonstrator-App zeigt praxisnah, wie Mitarbeiter per mobiler Lösung Paletten erfassen, verifizieren und mit Warenwirtschaftsdaten abgleichen können.

Innovationshöhe und industrielle Anwendungsmöglichkeiten:

Die Kombination modernster KI-Verfahren, modularem Softwaredesign und industriell relevanter Anwendungslogik (Lagerstandortverortung, Packmusteranalyse, Labelauswertung) stellt eine in dieser Form bislang nicht verfügbare Lösung dar. Die Innovation liegt vor allem in der Kombination und Systemintegration dieser Technologien, nicht nur in der Einzelanwendung. Insgesamt fördern die Projektergebnisse die Digitalisierung und Automatisierung intralogistischer Prozesse, insbesondere im Bereich der Palettenerfassung, -prüfung und -dokumentation. Sie tragen damit direkt zur Effizienzsteigerung, Qualitätssicherung und Wettbewerbsfähigkeit mittelständischer Unternehmen bei.

5 Wissenstransfer in die Wirtschaft

Tabelle 1: Wissenstransfermaßnahmen

Maßnahme	Ziel	Ort/Rahmen	Datum/Zeitraum
1. Sitzung projektbegleitender Ausschuss (PA)	Projektvorstellung, Aufnahme Anforderungen und Ziele PA	BIBA und virtuell	29.04.2024 - angeboten
Erstellen einer Projekt-Webseite	Öffentlichkeitsarbeit für das Projekt. Zentrale Informationsquelle für das Projekt und begleitende Informationsquelle für die Forschungsergebnisse.	https://pakur.biba.uni-bremen.de/	Online gestellt
Sitzung projektbegleitender Ausschuss (PA)	Stand des Projekts und Kooperationsmöglichkeiten	BIBA und virtuell	19.09.2024 - angeboten

6 Durchgeführte Transfermaßnahmen

Tabelle 2: Transfermaßnahmen innerhalb der Projektlaufzeit

Maßnahme	Ziel	Ort/Rahmen	Datum/Zeitraum
Wissenschaftliche Verwertung in Form von Publikationen in Fachzeitschriften sowie der Präsentation auf Messen und Fachkonferenzen	Veröffentlichung der Ergebnisse zu Erweiterung des Stands der Wissenschaft. Förderung des wissenschaftlichen Austausches und Diskussion.	Zeitschriften Konferenzen Messen	
Konferenzbeitrag		Neapel / "Vision-Based Pallet Detection and Load Height Estimation for Autonomous Material Handling Systems" auf der CIRP ICME 2024	10.-12.07.2024 warten auf Veröffentlichung
Konferenzbeitrag		Neapel / "Evaluating Zero-Shot Image Segmentation Methods for Parcel Detection" auf der CIRP ICME 2024	10.-12.07.2024 warten auf Veröffentlichung
Keynote/Vortrag		Bremen / Impulsvortrag: KI-Anwendungen in der Logistik auf der Mensch und KI in der Logistik der Zukunft	22.05.2025
Keynote/Vortrag		Bremerhaven / KI-Anwendungen in der Logistik auf der Digitale Innovation in der Industrie und im Mittelstand: Künstliche Intelligenz als Standortvorteil	26.11.2024

7 Geplante spezifische Transfermaßnahmen nach der Projektlaufzeit

Tabelle 2: Transfermaßnahmen nach Projektende

Maßnahme	Ziel	Ort/Rahmen	Datum/Zeitraum
Verbreitung der Arbeitsergebnisse in Form von Publikationen in Fachzeitschriften sowie der Vorstellung der Projektergebnisse auf Messen und Kongressen.	Publikation der Ergebnisse und Steigerung der Nutzerzahl der Bibliothek.	Zeitschriften Konferenzen Kongresse Weitere Konferenzbeitrag geplant Journalbeitrag geplant	Ca. 3 Monate nach Projekteende
Weiterentwicklung der Forschungsinhalte im	Steigerung der Nutzerzahl der Bibliothek durch	BIBA	Direkt nach Projekt-Ende

Rahmen eines Folgeprojekts. Fokus auf Verbesserung der Performance bei Härtefällen sowie weitere Vereinfachung des Transfers in die Praxis, basierend auf PA-Feedback.	dessen Verbesserung sowie durch weiter vereinfachte Nutzungsmöglichkeiten. Außerdem hinzufügen weiterer Features wie der automatischen Oberflächendefekterkennung oder Portierung in andere Anwendungsfelder.		In Planung
Software Bibliothek, Trainingsdaten und Benchmarkdatensatz, sowie das Frontend öffentlich verfügbar machen.	Reichweite und Nutzbarkeit erhöhen und wissenschaftlichen Austausch anregen.	Gitlab und die Projektwebsite	Direkt nach Projekt-Ende

8 Literaturverzeichnis