

Federführung: Fraunhofer-Institut für Mikroelektronische Schaltungen und Systeme IMS
Krohne Messtechnik GmbH
Universität Duisburg-Essen

Abschlussbericht Alventory (Automatisierung Inventarisierung mittels KI)

14.09.2026

Koordination:
Ole Werger (Projektleitung)

Fraunhofer IMS

Telefon 0203/3783-281

E-Mail ole.werger@ims.fraunhofer.de

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

Die Landesregierung
Nordrhein-Westfalen



5-StandorteProgramm



Inhalt

1	Zusammenfassung.....	3
2	Wissenschaftliche Ergebnisse.....	4
2.1	Projektergebnisse und Zielerreichung.....	4
2.1.1	AP1 Datenaufnahme.....	4
2.1.2	AP2 Segmentierung	4
2.1.3	AP3 Abgleich	4
2.1.4	AP4 App-Integration	5
2.2	Lösungskonzept	5
2.2.1	Allgemeines Vorgehen	5
2.2.2	Segmentierung.....	5
2.2.3	Abgleich.....	8
2.2.4	App-Integration.....	10
2.3	Verwertung.....	10
3	Zusammenarbeit.....	11
4	Einordnung im ZaKI.D-Kontext.....	11

1 Zusammenfassung

Dieses Projekt wurde mit dem Spielwarenladen „Roskothen – Die Kunst zu spielen“¹ durchgeführt. Das traditionsreiche Fachgeschäft besteht seit 1879 in der Duisburger Innenstadt und ist weit über die Stadtgrenzen hinaus für sein umfangreiches und vielfältiges Sortiment an Gesellschaftsspielen sowie weiteren Spielwaren bekannt.

Da täglich zahlreiche neue Spiele ausgestellt, verkauft oder innerhalb der Verkaufsfläche umplatziert werden, verändert sich der Bestand der Regale kontinuierlich. Um sicherzustellen, dass möglichst alle verfügbaren Spiele auf der Verkaufsfläche präsent sind, müssen Produkte regelmäßig aus dem Lager nachgeräumt werden. Dieser Prozess erfolgt bislang ausschließlich manuell: Mitarbeitende erfassen zunächst den Bestand auf der Verkaufsfläche und prüfen anschließend im räumlich getrennten Lager, ob entsprechende Spiele verfügbar sind. Unterstützt wird dieser Vorgang derzeit durch Fotos, die mit Smartphones oder Tablets aufgenommen werden. Dieser bildbasierte Arbeitsablauf sollte im Rahmen des Projekts möglichst beibehalten und nicht grundlegend verändert werden.

Ziel des Projekts ist ein Machbarkeitsnachweis. Überprüft wurde, wie die Inventarisierung des Spielwarenladens mithilfe künstlicher Intelligenz unterstützt werden kann. Hierfür wurde ein Ansatz entwickelt, bei dem jeweils ein Foto der Verkaufsfläche sowie ein Foto des Lagerbestands aufgenommen und anschließend automatisiert miteinander abgeglichen werden.

Das Ergebnis dieses Abgleichs ist eine Übersicht der Spiele, die ausschließlich auf dem Lagerfoto erkannt wurden und somit potenziell auf der Verkaufsfläche fehlen. Der entwickelte Ansatz wurde anhand eines unabhängigen Testdatensatzes evaluiert; dabei konnte eine Genauigkeit von ca. 80% erreicht werden, was die generelle technische Machbarkeit nachweist.

Abschließend wurde dem Projektpartner aufgezeigt, welche weiteren Schritte und Anpassungen in einem möglichen Folgeprojekt notwendig wären, um die entwickelte Lösung produktiv im Geschäftsalltag einsetzen zu können.

¹ <https://www.diekunstzuspielen.de/>

2 Wissenschaftliche Ergebnisse

2.1 Projektergebnisse und Zielerreichung

Im Projekt „Alventory“ sollte nachgewiesen werden, dass die Inventarisierung mit Nachräumen fehlender Spielwaren durch KI unterstützt werden kann. Der Prozess, der von Mitarbeitenden im Unternehmen bislang manuell durchgeführt wurde, dient dabei als Basis und wird um unterstützende Komponenten erweitert. Dies wurde in vier Arbeitspakete aufgeteilt, die nachfolgend genauer beschrieben werden:

2.1.1 AP1 Datenaufnahme

Es sollten keine Daten zum Training von KI-Modellen aufgenommen werden, sondern nur Evaluationsdaten. Diese Daten werden benötigt, um die Qualität der Unterstützung messbar zu machen.

Zielerreichung: Es wurden insgesamt an verschiedenen Tagen ca. 1000 Fotos von der Verkaufsfläche angefertigt. Diese Fotos wurden strukturiert analysiert und persistent gespeichert. Das Ziel wurde vollständig erreicht.

Ergebnis: Der entstandene Datensatz stellt nur die Begebenheiten vor Ort in diesem Einzelfall da, gegebenenfalls kann die Übertragbarkeit auf andere Spielwarenläden nur eingeschränkt funktionieren. Es sind zudem zwei Datensätze zur Bewertung der Objektsegmentierung erstellt worden: Einer unter Laborbedingungen am Institut (20 Bilder mit 496 Annotationen) und ein Datensatz mit Bildern aus dem tatsächlichen Laden (36 Bilder mit 2180 Annotationen).

2.1.2 AP2 Segmentierung

Die Spielwaren auf einem Foto sind in den meisten Fällen in rechteckigen Schachteln verpackt. Nur in Einzelfällen bei über 4.000 Produkten trifft dies nicht zu. Entsprechend werden in einem ersten Schritt rechteckige Boxen auf dem Foto erkannt. Aus diesen Boxen kann dann jeweils entweder direkt ein „Embedding“ generiert werden oder es wird zusätzlich noch ein OCR-Verfahren angewendet.

Zielerreichung: Die Boxerkennung geschieht mit einer Genauigkeit von 80% mAP50. Das Ziel wurde vollständig erreicht.

Ergebnis: Auf dem Labordatensatz wird ein mAP50-Wert von 98,22% erreicht und auf dem realen Testdatensatz 93,53%.

Die Erkennung von Boxen wird sogar beim Anfertigen des Fotos bereits „in nahezu Echtzeit“ eingeblendet, sodass der/die fotografierende Mitarbeitende bei Fehlern direkt nachsteuern könnte.

Der Einsatz synthetischer Daten zur Verbesserung der Segmentierungsleistung erwies sich als vorteilhaft. Durch die Ergänzung synthetischer Daten konnte der mAP50-Wert auf den Labordaten von 93,96 % auf 98,22 % gesteigert werden. Gleichzeitig zeigte sich jedoch, dass ein Training ausschließlich auf synthetischen Daten der Kombination aus realen und synthetischen Daten unterlegen war. In diesem Fall mit nur synthetischen Trainingsdaten wurde lediglich ein mAP50-Wert von 95,55 % erreicht.

2.1.3 AP3 Abgleich

Wenn ein oder mehrere Fotos aus der Verkaufsfläche und ein Foto bzw. Videostream aus dem Laden vorliegen, dann werden diese automatisiert abgeglichen. Dazu werden die generierten Embeddings

(Vektoren) aller erkannten Spielwaren-Boxen per Kosinus-Ähnlichkeit verglichen und zusätzlich wird der Text innerhalb jeder Box noch per OCR analysiert, sodass zusätzlich auch die textuelle Beschreibung verglichen werden kann. Spiele aus dem Lager denen kein Partner aus dem Laden zugeordnet werden kann, gelten dann als „fehlend“.

Zielerreichung: Der Abgleich zweier Bilder soll auf dem Testdatensatz einen F1-Score von 0.5 erreichen. Dazu wird bewertet, wie viele fehlende Spielwaren richtig erkannt wurden (Recall) und wie viele Vorhersagen korrekt waren (Precision). Das Ziel wurde vollständig erreicht.

Ergebnis: Die Testdaten sind nur für diesen Spielwarenladen repräsentativ. Der F1-Score beträgt hier 0.79, was für einen Machbarkeitsnachweis ausreichend ist. Während der Arbeit an diesem Arbeitspaket ist besonders aufgefallen, dass sehr ähnliche Spiele (z.B. Erweiterungen oder neue Versionen desselben Spiels) sich schlechter unterscheiden lassen und zu Fehlern führen. Hier sollte im potenziellen Folgeprojekt noch mal nachgearbeitet werden.

2.1.4 AP4 App-Integration

Um das System nutzbar zu machen, wurde die Integration in Smartphones und Tablets angestrebt. Die verwendeten Algorithmen sind jedoch sehr ressourcenintensiv und benötigen dedizierte Hardware. Damit der/die benutzende Mitarbeitende dennoch das vertraute Smartphone verwenden kann, wurde eine Web-Applikation entwickelt, die auf einen lokalen Server zugreift und so die Fotos und Informationen austauscht.

Zielerreichung: Die Ergebnisse der vorherigen Arbeitspakete werden in eine gemeinsame Pipeline überführt und auf einem Smartphone getestet. Das Ziel wurde vollständig erreicht.

Ergebnis: Da es sich hier um keine native App-Entwicklung handelt, reicht als Nachweis die Bedienung mittels eines handelsüblichen Smartphones. Dies wurde grundlegend umgesetzt. In einem potenziellen Folgeprojekt könnte hier noch weiterer Entwicklungsaufwand für die Verbesserung der Benutzenden-Interaktion aufgebracht werden.

2.2 Lösungskonzept

In diesem Abschnitt wird das ganzheitliche Lösungskonzept für die Problemstellung des Projektes zusammengefasst.

2.2.1 Allgemeines Vorgehen

Bislang nimmt der/die Mitarbeitende auf der Verkaufsfläche ein Foto auf. Dieses Foto stellt alle Spielwaren (eines bestimmten Bereichs) dar, die aktuell gekauft werden können. Im Lager wird dieses Foto dann mit den verfügbaren Spielen abgeglichen. Fehlende Spiele werden erkannt und auf die Verkaufsfläche nachgeräumt. Genau da setzt auch die entwickelte Lösung an: Es wird ein zweites Foto, aber von der Lagerfläche, aufgenommen. Die KI-Modelle erkennen automatisch welche Spiele nicht auf dem Ladenfoto vorliegen und heben die fehlenden Spiele visuell im Lagerfoto hervor. Dies ist mit einigen technischen Details in Abbildung 1 dargestellt. Die Erkennung der Spielwaren wird detaillierter in Abschnitt 2.2.2 beschrieben, der Abgleich der Spielwaren in Abschnitt 2.2.3. Die Benutzenden-Interaktion wird per Web-Applikation unterstützt, welche in Abschnitt 2.2.4 erläutert wird.

2.2.2 Segmentierung




Abbildung 1: Entwickelte Pipeline zur Detektion fehlender Spiele auf der Verkaufsfläche

Die Boxerkennung der Spielwaren wird mit dem Modell RF-DETR¹ durchgeführt. Eingabe des Modells ist ein Foto. Ausgabe des Modells sind rechteckige Boxen und die „Confidence“, die angibt, wie sicher sich das Modell mit dieser Vorhersage ist. In Abbildung 2 wird diese Ausgabe grafisch dargestellt. Der



Abbildung 2: Objekterkennung auf Beispielfoto

¹ <https://rfdetr.roboflow.com/latest/>

Vorteil dieser Variante ist, dass es bereits Modelle gibt, die auf diversen rechteckigen Objekten vortrainiert wurden. Das hier verwendete Modell wurde auf dem COCO-Datensatz¹ vortrainiert. Für diese Anwendungsfälle sollte das Modell idealerweise auf gelabelten Daten des Projektpartners feinabgestimmt und damit gezielt auf diese Daten spezialisiert werden. Da die Labeling-Erstellung jedoch sehr aufwändig ist und vor Projektbeginn keine entsprechenden Daten verfügbar waren, wurde stattdessen der öffentliche Datensatz **SKU-110K**² verwendet. Dieser bildet zwar nicht die Gegebenheiten exakt ab, nähert diese aber gut an, da er viele Bilder mit dicht beieinander liegenden Objekten enthält. Über einen Schwellwert kann die Genauigkeit der zu erkennenden Boxen eingestellt werden. Ein zu hoher Schwellwert bedeutet beispielsweise, dass ggf. weniger Boxen erkannt werden, als vorhanden sind.

Um die Anpassung des Modells an die Zieldomäne weiter zu verbessern, wurde eine Pipeline zur Generierung synthetischer Trainingsdaten entwickelt, die lediglich eine kleine Sammlung nicht-annotierter Referenzbilder der Zielprodukte voraussetzt. Die Pipeline kombiniert zwei komplementäre Ansätze: das Cut-and-Paste-Verfahren³, bei dem segmentierte Objektinstanzen auf Hintergrundbilder platziert werden, sowie eine diffusionsbasierte Hintergrundaugmentierung mittels Inpainting⁴. Ein wesentlicher




Abbildung 1: Methodik zur Generierung synthetischer Trainingsdaten für die Objektsegmentierung

Vorteil dieser Kombination ist, dass keine realen Hintergrundbilder manuell gesammelt werden müssen, da diese per Text-zu-Bild-Synthese auf Basis variabler Prompts generiert werden. Der manuelle Aufwand beschränkt sich damit auf die Erfassung und Segmentierung der Vordergrundobjekte. In diesem Fall Brettspielkartons, die im Zielszenario aufgenommen und mit SAM automatisch segmentiert wurden. Ein regelbasiertes Cut-and-Paste-Modul ordnet diese Instanzen anschließend in Regalanordnungen an und variiert dabei Position, Skalierung und gelegentlich die Tiefenrotation. Die zugehörigen

¹ <https://cocodataset.org/#home>

² https://github.com/eg4000/SKU110K_CVPR19

³ <https://arxiv.org/abs/1708.01642>

⁴ <https://arxiv.org/abs/2408.00350>

Bounding-Box-Annotationen werden direkt aus den platzierten Instanzpositionen abgeleitet. Im zweiten Schritt werden alle nicht durch Objekte bedeckten Hintergrundbereiche mit einem vortrainierten Stable Diffusion XL-Modell¹ mittels Inpainting ausgefüllt, sodass vollständige Bilder entstehen. Das Modell ist dabei konditioniert auf einen generischen Regalszenen-Prompt, damit die entstehenden Bilder möglichst natürlich aussehen. Abschließend wird der SDXL Refiner² mit geringer Denoising-Stärke auf das Gesamtbild angewendet, um Objektränder zu harmonisieren und die visuelle Kohärenz zwischen eingefügten Instanzen und generiertem Hintergrund zu verbessern. Die resultierende Pipeline ist in Abbildung 1 dargestellt.

Insgesamt wurden so 1600 weitere Bilder zum Trainieren des Segmentierungsmodell generiert. Das finale Modell wurde zunächst über 20 Epochen auf dem Datensatz SKU-110K trainiert. Anschließend wurde es mit einer reduzierten Lernrate für weitere drei Epochen auf synthetischen Daten feinabgestimmt.

2.2.3 Abgleich

Damit ein Spiel auf zwei unterschiedlichen Fotos erkannt und zugeordnet werden kann, werden „Embeddings“ und zusätzliche OCR-Verfahren verwendet. In Abbildung 2 wird dargestellt, wie der Embedding-Vergleich funktioniert. Dieser und weitere Teilaspekte werden nachfolgend erläutert:




Abbildung 2: Embedding-Vektoren werden pro Box erzeugt und per Kosinus-Ähnlichkeit verglichen. 0 bedeutet keine Übereinstimmung und 1 eine volle Übereinstimmung.

Generierung von Embedding pro Box

Einfache Vergleiche können vor allem durch numerische Gleichungen getätigt werden. Da Fotos aber sehr variabel sind und trotzdem das gleiche Objekt darstellen können, wurden Verfahren ermittelt, welche aus einem Foto einen repräsentativen numerischen Vektor (Embedding) erzeugen. Hierfür wurden Convolutional Neuronal Networks (CNN) eingesetzt. Für ein Eingabebild werden die Aktivierungen an einer Zwischenschicht des Netzes ausgelesen und als Embedding des Eingabebilds gewertet.

¹ <https://arxiv.org/abs/2307.01952>

² <https://huggingface.co/stabilityai/stable-diffusion-xl-refiner-1.0>

Dies wurde in diesem Projekt mit den Modellen MobileNet¹, EfficientNet² und ResNet³ gemacht (vergleichbare Performanz). Diese Modelle sind auf großen Mengen vielfältiger Bilder vortrainiert und liefern informative Embeddings. Um die Modelle auf die Domäne der Brettspielboxen zu spezialisieren, wurden die Modelle nachtrainiert. Dafür wurde ein Datensatz von BoardGameGeeks⁴ verwendet. Dieser unterliegt speziellen Lizenzbedingungen für Forschungseinsätze und kommerzieller Nutzung. Für das Nachtrainieren wurde eine selbstüberwachte Lernmethode (BYOL⁵) eingesetzt, die das aufwendige Annotieren der Bilder vermeidet.

Kosinus- Ähnlichkeit

Die Ähnlichkeit zwischen zwei Vektoren kann am einfachsten über die Kosinus-Distanz oder auch Kosinus-Ähnlichkeit berechnet werden. Gleichung 1 ist die Formel, die zur Berechnung herangezogen wird. Dabei wird der Kosinus des Winkels zwischen zwei Vektoren (a und b) berechnet. Der Wertebereich verläuft von -1 bis 1, wobei -1 eine entgegengesetzte Richtung und 1 gleichgerichtet bedeutet. Die Embedding-Vektoren sind nicht negativ, daher wird hier die Ähnlichkeit nur zwischen 0 (gänzlich verschieden) und 1 (identisch) liegen. $\|a\|$ ist hierbei die euklidische Norm des Vektors a und n ist die Dimension (Anzahl der Komponenten) des Embedding-Vektors.

$$\text{Kosinus-Ähnlichkeit} = \cos \theta = \frac{a \cdot b}{\|a\| \|b\|} = \frac{a \cdot b}{\sqrt{a^2 \cdot b^2}} = \frac{\sum_{i=1}^n a_i \cdot b_i}{\sqrt{\sum_{i=1}^n (a_i)^2} \cdot \sqrt{\sum_{i=1}^n (b_i)^2}}$$

Gleichung 1

OCR-Verfahren

Da sich Spiele teilweise nicht mal in Grafik und Titel, sondern nur in kleinsten Details, wie z.B. Untertitel unterscheiden, wurde das entwickelte Verfahren um eine OCR-Komponente erweitert. Diese sorgt bei erkanntem Text auf einer Spielschachtel für eine Erhöhung der Genauigkeit, da sie Unterschiede in Namen o.ä. erkennen kann. Eine alleinige Verwendung von OCR hingegen ist ausgeschlossen, da verschnörkelte Schriften oder Seitenansichten ohne Text nicht verarbeitet werden könnten, aber wiederum den Regelfall darstellen. Für das OCR-Verfahren wurde hier PaddleOCR⁶ verwendet. Für zusätzliche Genauigkeit wird erkannter Text mit einer Liste existierenden Titel (von BoardGameGeek) verglichen und der ähnlichste Title ausgewählt und dem Foto des Spiels zugeordnet

Abgleich und Identifikation fehlender Spiele

Für alle Spiele, sowohl im Laden als auch im Lager, werden die Titel mittels OCR bestimmt und die Embeddings berechnet. Anschließend wird die Kosinus-Ähnlichkeit der Embeddings zwischen allen Spielen berechnet. Anhand dieser Daten wird versucht, jedes Spiel im Lager einen Partner aus dem Laden zuzuordnen. Falls für zwei Spiele die identischen Titel ausgelesen wurden, gelten diese als zugeordnet. Für die übrigen Spiele aus dem Lager wird der Partner aus dem Laden gesucht, der die höchste

¹ <https://keras.io/api/applications/mobilenet/>

² <https://www.ultralytics.com/de/blog/what-is-efficientnet-a-quick-overview>

³ <https://www.ultralytics.com/de/glossary/residual-networks-resnet>

⁴ <https://boardgamegeek.com/browse/boardgame>

⁵ <https://arxiv.org/abs/2006.07733>

⁶ <https://aistudio.baidu.com/paddleocr>

Kosinus-Ähnlichkeit aufweist (Top-1 Matching). Ist die höchste Ähnlichkeit geringer als ein festgelegter Schwellenwert, wird diesem Spiel kein Partner zugeordnet und als fehlend definiert. Hierbei wird jedes Spiel aus dem Lager getrennt ausgewertet, da so sowohl mehrfaches Vorkommen desselben Spiels wie auch unterschiedliche Anzahlen an Spielen auf den Fotos berücksichtigt werden können.

2.2.4 App-Integration

Um die Algorithmen nutzbar zu machen, werden die vorgestellten Teilkomponenten in einem Gesamtsystem mittels Web-Applikation nutzbar gemacht. Neben einem Server, der über die notwendigen Hardware-Ressourcen verfügt, kommt ein Smartphone oder Tablet zum Einsatz, mit dem die Fotos aufgenommen werden können und welches die Ergebnisse visuell darstellt. Um Plattform unabhängig zu bleiben, wird dies als Website im lokalen Netzwerk eingerichtet, so können verschiedene Geräte unabhängig voneinander diese Aufgaben absolvieren.

2.3 Verwertung

In dem Projekt wurde ein System zur automatisierten Inventur und zum Abgleich zweier Spielwarenbestände entwickelt. Die Lösung kann auch auf andere Anwendungsbereiche übertragen werden. Die Vermarktung der Ergebnisse obliegt beiden Partnern jeweils selbst. Das Fraunhofer IMS wird über dieses Projekt unter Nennung des Projektpartners „Roskothen – Die Kunst zu spielen“ im Kontext des ZaKI.Ds berichten.

Zusätzlich sollen die gewonnenen Erkenntnisse – insbesondere zum Einsatz synthetischer Daten und zur Nutzung des Systems ohne aufwändige Bildannotation – in einer wissenschaftlichen Veröffentlichung dokumentiert werden.

Für die Integration in den tatsächlichen Prozess und den Einsatz unter realen Bedingungen muss der Embedding-Abgleich weiter robust gestaltet werden. Dazu sollten zusätzliche Grenzfälle berücksichtigt und bei Bedarf feste regelbasierte Bedingungen ergänzt werden.

Außerdem müssen alle eingesetzten KI-Modelle weiter an die spezifischen Anwendungsfälle und Rahmenbedingungen angepasst werden.

3 Zusammenarbeit

Die Zusammenarbeit verlief stets flexibel, lösungsorientiert und eng abgestimmt. Status-Updates seitens des Projektteams erfolgten anlassbezogen und zeitnah per E-Mail und Telefon. Ergänzend wurden bei Vor-Ort-Terminen mit dem Inhaber und den Mitarbeitenden des Spielwarenladens weitere Details in einem persönlichen Austausch besprochen. Der geplante Zeitrahmen wurde dabei durchgehend eingehalten.

4 Einordnung im ZaKI.D-Kontext

Dieses Projekt war ein weiteres Umsetzungsprojekt des ZaKI.D-Projektes und das dritte durch das Fraunhofer IMS abgeschlossene Umsetzungsprojekt.

ZaKI.D hat unter anderem zum Ziel auch die Auswirkung auf die 17 Ziele zur nachhaltigen Entwicklung der Vereinten Nationen zu betrachten. Mit dem durchgeführten Projekt werden die folgenden Ziele unterstützt:

SDG 8 MENSCHENWÜRDIGE ARBEIT UND WIRTSCHAFTSWACHSTUM

Die Automatisierung zeitaufwendiger Inventurprozesse reduziert manuellen Aufwand und steigert die betriebliche Effizienz. Mitarbeitende können sich stärker auf wertschöpfende Tätigkeiten konzentrieren. Beitrag zu: Produktivitätssteigerung, Entlastung administrativer bzw. repetitiver Tätigkeiten, Unterstützung von KMU bei der Digitalisierung.

SDG 9 INDUSTRIE, INNOVATION UND INFRASTRUKTUR

Alventory digitalisiert und automatisiert Inventarisierungs- und Bestandsprozesse durch den Einsatz von KI-gestützter Bilderkennung und Datenanalyse. Dadurch werden betriebliche Infrastrukturen modernisiert und digitale Prozesse in Unternehmen gestärkt. Beitrag zu: Digitalisierung betrieblicher Abläufe, Einsatz innovativer KI-Technologien in Unternehmen, intelligente Datenverarbeitung für industrielle Anwendungen.

SDG 12: NACHHALTIGE/R KONSUM UND PRODUKTION

Eine präzisere Bestandsverwaltung hilft Unternehmen dabei, Ressourcen effizienter zu nutzen. Durch bessere Transparenz über vorhandene Materialien oder Werkzeuge können Überbestände, Fehlkäufe und unnötige Lagerhaltung reduziert werden. Beitrag zu: Effizienterer Ressourcennutzung, Vermeidung von Materialverschwendung, optimierte Lager- und Bestandsprozesse)