

KI-Sortierung für Seltene-Erden-Pumpen: Eine Fallstudie mit WILO

David Rohrschneider, Kevin Kurpierz, Edgar Oberdoerfer, Nermeen Abou Baker

Seltene Erden (SE) sind für moderne Technologien unverzichtbar, doch ihre Wiederverwertung gestaltet sich nach wie vor schwierig. Während Herstellung und Vertrieb von Produkten mit SE meist gut strukturiert sind, fehlt es häufig an einheitlichen Verfahren zur Sammlung und Rückgewinnung dieser Elemente aus alten Produkten.

WILO, ein Unternehmen, das für die Herstellung innovativer Pumpensysteme bekannt ist, hat bereits Rücknahme- und Recyclingverfahren etabliert, um SE aus gebrauchten Pumpen zurückzugewinnen. Da nicht jede zurückgegebene Pumpe SE enthält und einzelne Exemplare hinsichtlich Bauweise und Zustand stark voneinander abweichen, ist dieser Prozess aktuell zeit- und kostenaufwändig. Der Einsatz von Künstlicher Intelligenz (KI) und maschinellem Sehen bietet dabei einen vielversprechenden Ansatz zur automatisierten Sortierung, da sie Muster in komplexen Daten erkennen und sich an unbekannte Situationen anpassen können.

Die vorliegende Fallstudie, die in Zusammenarbeit mit der Hochschule Ruhr West durchgeführt wurde, evaluiert die Umsetzbarkeit eines KI-basierten visuellen Erkennungssystems zur automatisierten Vorsortierung von SE-haltigen Pumpen am WILO-Recyclingstandort in Dortmund.

Pumpen in kritischen Rohstoffzyklen

Pumpen zählen zu den am weitesten verbreiteten Maschinen in zahlreichen Branchen, darunter Fertigung, Energieversorgung, Wasserwirtschaft, chemische Industrie und Lebensmittelproduktion. Durch technologische Fortschritte werden immer mehr Pumpen mit hocheffizienten Permanentmagnetmotoren ausgestattet, die oftmals SE (z.B. Neodym) enthalten. Auch Sensoren, Steuerungseinheiten und weitere elektronische Komponenten in diesen Systemen sind häufig auf SE angewiesen.

Obwohl SE in vielen Regionen der Welt vorkommen, konzentrieren sich Abbau und Verarbeitung auf wenige Gebiete. Diese Konzentration führt zu geopolitischen Abhängigkeiten, schwankenden Preisen und erhöhten Versorgungsrisiken.

Recycling und andere Strategien einer Kreislaufwirtschaft können dazu beitragen, diese Risiken zu verringern, jedoch sind geschlossene Stoffkreisläufe in der Pumpenbranche bislang selten. Herkömmliche Zerkleinerungsverfahren führen oft dazu, dass SE-haltige Komponenten in ungeeignete Stoffströme gelangen und nicht mehr zurückgewonnen werden können.

Auf dem Weg zu effizientem Pumpen-Recycling bei WILO

Zur Unterstützung der Materialrückgewinnung hat WILO ein Rücknahmesystem für Pumpen eingerichtet. Handwerksbetriebe können alte Pumpen, unabhängig von Marke, Alter oder Zustand, direkt beim Großhändler abgeben. Darüber hinaus können beim Ausliefern neuer Pumpen die ausgedienten Pumpen eingesammelt und zum unternehmenseigenen Recyclingzentrum in Dortmund transportiert werden.

Im Recyclingzentrum werden die zurückgegebenen Pumpen gesammelt und für die weitere Verarbeitung manuell sortiert. Obwohl WILO bereits ein Recyclingverfahren für Pumpen mit SE entwickelt hat, treffen diese in der Regel in gemischten Chargen ein, wobei einige Pumpen Sensoren oder Steuereinheiten enthalten, die eine besondere Behandlung erfordern (siehe Abbildung 1). Daher muss die Sortierung derzeit von geschultem Personal durchgeführt werden. Zwar können Experten vor Ort SE-haltige Pumpen schnell identifizieren, doch der manuelle Prozess ist zeit- und kostenintensiv, was die effiziente Skalierung der Recyclingaktivitäten erschwert.

Abbildung 1: Beispiel einer Gitterbox mit verschiedenen Pumpen.





Datenbasierte Methoden, insbesondere Deep-Learning-Technologien im Bereich des maschinellen Sehens, bieten erhebliches Potenzial zur Automatisierung solcher Sortierprozesse (Abou Baker, N.; Handmann, U., 2022). Neben der gezielten Vorsortierung für das Recycling eröffnen sich weitere Einsatzmöglichkeiten wie KI-gesteuerte Demontageprozesse (Díaz, I. et al., 2025) oder prädiktive Wartung (Scaife, A. D., 2023), die die Lebensdauer von Komponenten verlängern können.

Moderne Objekterkennungssysteme bieten daher großes Potenzial, die Effizienz der Vorsortierung zu steigern, indem sie Pumpentypen und deren genaue Position in gemischten Sammelboxen präzise identifizieren. Die vollständige Automatisierung des Sortierprozesses stellt jedoch eine komplexe Herausforderung dar und setzt eine präzise Entwicklung sowie eine umfassende Erprobung der eingesetzten KI-Modelle voraus. Gründe dafür sind unter anderem geringe visuelle Unterschiede, die Vielzahl an Modellen und Bauformen sowie individueller Verschleiß über die Nutzungsdauer hinweg.

Außerdem erfordert die Einführung automatisierter Prozesse nicht nur eine technologische, sondern auch eine wirtschaftliche und ökologische Abwägung. Eine kontinuierliche Überwachung ressourcenbezogener Kennzahlen, wie etwa des Energieverbrauchs durch leistungsstarke Rechner und Robotiksysteme, ist deshalb ebenso wichtig wie die Verlässlichkeit der KI-Modelle.

Diese Pilotstudie konzentriert sich zunächst auf eine zentrale Forschungsfrage: Ist es modernen KI-Modellen möglich, Pumpen mit SE anhand von Bildern aus unterschiedlich gefüllten, gemischten Sammelboxen zuverlässig zu identifizieren? Die Ergebnisse sollen Aufschluss darüber geben, ob eine KI-basierte Vorsortierung alter Pumpen in einem industriellen Umfeld umsetzbar ist.

Instanzsegmentierung: Technischer Hintergrund

Im Gegensatz zu Daten, die von LiDAR, Radar oder Tiefenkameras erfasst werden und räumliche Informationen liefern, sind Bilder herkömmlicher Kameras im Wesentlichen zweidimensional. Die Farbinformation kann dabei eine zusätzliche Dimension darstellen, wodurch der Informationsgehalt jedes einzelnen Pixels erweitert wird.

Maschinelles Sehen orientiert sich stark am menschlichen Sehsinn: Wie Menschen erkennen solche Systeme zunächst Kanten und Kontraste und bauen darauf komplexe Muster auf. So lassen sich Objekte in Bildern erkennen und kategorisieren.

Im maschinellen Sehen können Muster auf verschiedenen Detalebenen erkannt werden: In der herkömmlichen Bildklassifikation wird einem gesamten Bild ein einziges Label zugewiesen. Die Objekterkennung identifiziert mehrere Objekte in einer Szene, versieht sie mit Labels und zeichnet einen Begrenzungsrahmen um jedes Objekt. Die semantische Segmentierung ordnet jedem Bildpixel eine Klasse zu, unterscheidet jedoch nicht zwischen Objekten derselben Klasse. Instanzsegmentierung

kombiniert diese beiden Ansätze: Sie erkennt jedes Objekt einzeln und erstellt dabei jeweils eine pixelgenaue Maske (Abou Baker, N.; Rohrschneider, D.; Handmann, U., 2024).

Im WILO-Recyclingzentrum besteht die Herausforderung der Vorsortierung zunächst darin, Pumpen mit SE-Komponenten aus gemischten Gitterboxen herauszufiltrieren. Hierbei ist der Einsatz von Instanzsegmentierung zwingend erforderlich, um jede einzelne Pumpe in einem unübersichtlichen Bild pixelgenau voneinander abzugrenzen. Dadurch können weitere Prozessschritte, beispielsweise das automatisierte Greifen der erkannten Pumpen durch Robotersysteme, effizient umgesetzt werden.

Um die Leistungsfähigkeit eines solchen Modells zu bewerten, werden üblicherweise drei zentrale Kennzahlen herangezogen, die dessen Stärken und Schwächen quantifizieren. Im Hinblick auf die Erkennung von Pumpen mit SE-Komponenten bedeuten diese im Einzelnen:

1. **Präzision:** Dieser Wert gibt an, wie viele der vom Modell als SE-haltig erkannten Pumpen tatsächlich SE enthalten. Eine hohe Präzision bedeutet also, dass das System nur selten fälschlicherweise Pumpen als SE-haltig klassifiziert, die in Wirklichkeit keine SE-Komponenten aufweisen.
2. **Sensitivität:** Diese Kennzahl beschreibt, wie viele der tatsächlich vorhandenen SE-haltigen Pumpen vom Modell erkannt werden. Ein hoher Wert zeigt an, dass das System wenige SE-haltige Pumpen übersieht.
3. **Mittlere Durchschnittliche Präzision (MDP):** Für Aufgaben der Instanzsegmentierung ist die MDP die wichtigste Bewertungsgröße. Sie berechnet die Durchschnittspräzision anhand verschiedener Schwellenwerte der Überschneidung zwischen vorhergesagten und tatsächlichen Segmentierungsmasken. Je höher der Schwellenwert, desto genauer müssen die vorhergesagten Grenzen mit den tatsächlichen übereinstimmen. Für jeden Schwellenwert wird eine Präzisions-Sensitivitäts-Kurve erstellt und die Fläche unter der Kurve beschreibt die durchschnittliche Präzision an diesem Punkt. MDP eignet sich besonders für Anwendungen, in denen exakte Segmentierungsgrenzen, wie etwa beim robotergestützten Greifen, erforderlich sind.

Versuchsaufbau

Um ein praxisnahes Konzept für die automatisierte Instanzsegmentierung zu entwickeln, ist zunächst ein strukturierter Datensatz mit ausreichend Bildern und Annotationen erforderlich. Bevor ein Modell trainiert werden kann, müssen daher aussagekräftige Bilddaten der realen Recyclingumgebung aufgenommen werden. Diese bilden die Grundlage für die Entwicklung und spätere Bewertung des Segmentierungsverfahrens.



Datenerfassung: Mehrere Gitterboxen mit unterschiedlichen Füllständen wurden manuell aus einer festen Überkopfposition fotografiert. Zwischen den einzelnen Aufnahmen wurden einige Pumpen aus der Box entnommen. Die unterschiedlichen Füllstände spiegeln realistische Bedingungen wider und lassen sich mit geringem Zusatzaufwand nutzen, um die Vielfalt des Datensatzes deutlich zu erhöhen. Insgesamt wurden 72 Bilder mit einer Auflösung von 2048 x 1536 Pixeln aufgenommen. Beispiele solcher Bilder sind in den Abbildungen 1 und 2 zu sehen.

Datenannotation: KI-Modelle benötigen für das überwachte Training beschriftete Daten, um Muster zu erkennen und zu lernen. Für die Instanzsegmentierung muss jedes Objekt im Bild manuell mit einem Polygon umrissen werden, um es klar von Hintergrund und anderen Objekten abzugrenzen. Anschließend wird jedem markierten Objekt eine Klassenbezeichnung zugeordnet. Diese Annotation erfolgte mithilfe der Plattform Roboflow (Roboflow, 2025). Da die Zielsetzung dieser Fallstudie die Erkennung von Pumpen mit SE ist, wurden andere Pumpen und Gegenstände nicht gekennzeichnet. Das Ergebnis dieser Prozedur ist ein Datensatz aus 72 Bildern mit insgesamt 377 annotierten SE-Pumpen.

Datenaugmentation: Um die Lernfähigkeit des Modells zu verbessern, wurde umfangreiche Datenaugmentation eingesetzt. Bei diesem Verfahren werden bestehende Bilder durch verschiedene Modifikationen verändert, um die Robustheit des Modells zu erhöhen und mehr Variabilität zu schaffen, ohne neue Fotos aufnehmen zu müssen. In diesem Fall wurden Rotationen, das Hinzufügen von Bildrauschen, Anpassungen der Helligkeit sowie Weichzeichnung eingesetzt. Durch diese Transformationen wurde der Datensatz von ursprünglich 72 Bildern auf insgesamt 1.224 augmentierte Bilder erweitert und bietet so eine deutlich bessere Trainingsgrundlage.

Datensataufteilung: Ein wesentlicher Schritt zur Bewertung der Generalisierungsfähigkeit eines Modells besteht darin, den Datensatz in Trainings- und Validierungssatz zu unterteilen. So

wird gewährleistet, dass das Modell an neuen Daten bewertet wird und echte Muster statt auswendig gelernter Beispiele erkennt. Nach der üblicherweise im maschinellen Lernen angewandten 80/20-Aufteilung besteht der finale Datensatz aus zufällig ausgewählten 980 Trainings- und 244 Validierungsbeispielen.

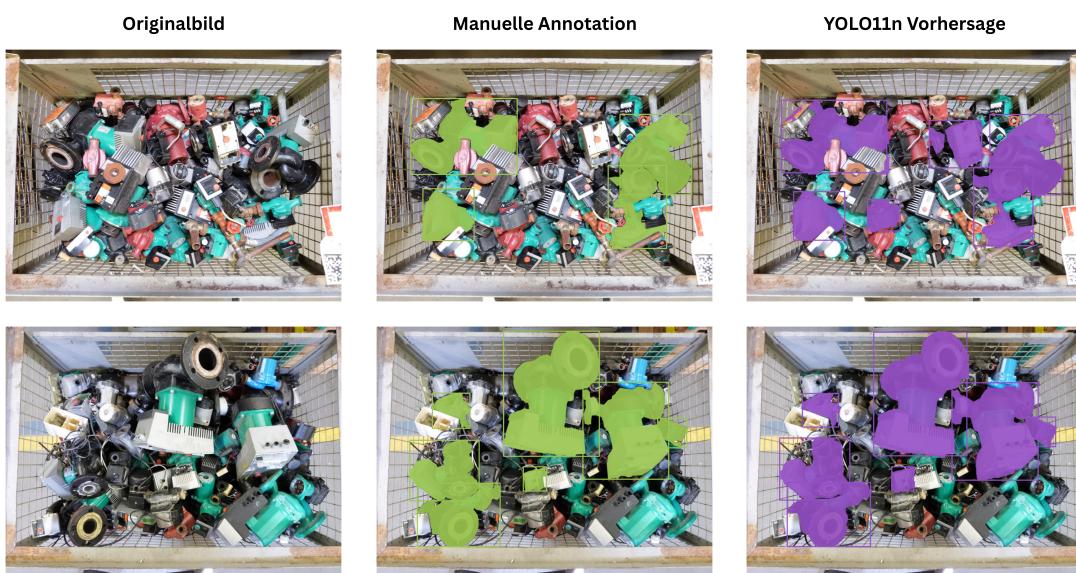
Modellauswahl und Training: Für diese Studie wurden Modelle der „You Only Look Once“ (YOLO)-Familie gewählt. YOLO-Modelle sind bekannt für ihre Geschwindigkeit und Genauigkeit bei verschiedenen Aufgaben des maschinellen Sehens (Abou Baker, N.; Rohrschneider, D.; Handmann, U., 2022). Ihre Effizienz sowohl auf Endgeräten als auch in der Cloud hat sie zu einer beliebten Wahl in Industrie und Forschung gemacht.

Konkret wurde das YOLOv11-Framework ausgewählt, wobei drei verschiedene Modellgrößen verglichen wurden: Nano, Small und Medium (Jocher, G., & Qiu, J., 2024). Jedes Modell wurde über 30 Epochen trainiert, sodass alle Trainingsdaten 30-mal durchlaufen wurden, um die Mustererkennung des jeweiligen Modells zu optimieren.

Ergebnisse und Diskussion

Der Großteil der Pumpen im Datensatz konnte von allen drei YOLOv11-Varianten zuverlässig erkannt werden, insbesondere solche mit sichtbaren digitalen Steuerelementen. Das kleinste Modell erzielte Präzisions- und Sensitivitätswerte von über 75 %, was zeigt, dass auch ressourcenschonende KI-Systeme komplexe Muster erlernen können. Abbildung 2 zeigt zwei qualitative Beispiele für die Stärken und Schwächen des YOLO11n-Modells. Der direkte Vergleich zwischen den Originalbildern (linke Spalte), den manuellen Annotationen in Grün (mittlere Spalte) und den Vorhersagen des YOLO11n-Modells in Lila (rechte Spalte) zeigt, wie das Modell unübersichtliche Szenen mit mehreren Pumpen analysiert und interpretiert.

Abbildung 2: Zwei qualitative Beispiele mit Originalbild (links), der manuellen Annotation (Mitte) und der Vorhersage (rechts).





Trotz der visuellen Unordnung gelingt es dem Modell, die meisten Pumpen in jeder Gitterbox zuverlässig zu erkennen, was seine robuste Leistungsfähigkeit unterstreicht. Die Segmentierung stimmt dabei eng mit den tatsächlichen Umrissen der Pumpen überein. Dies zeigt, dass das Modell eine sinnvolle Repräsentation von Form und Struktur der Pumpen erlernt hat und sich nicht nur auf einfache Merkmale wie Farbe oder Textur stützt.

Bei genauerer Betrachtung treten jedoch zwei typische Fehlerquellen zutage:

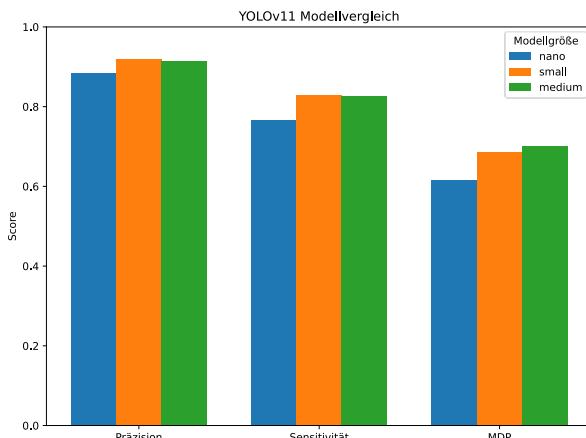
1. Pumpen mit SE, deren Steuermodul vollständig oder teilweise verdeckt ist, werden gelegentlich übersehen.
2. Pumpen mit Steuermodul, aber ohne SE, werden fälschlicherweise erkannt.

Diese Erkenntnisse deuten darauf hin, dass das Modell eine Abhängigkeit zwischen dem Vorhandensein eines Steuermoduls und SE gelernt hat. Obwohl die meisten Pumpen mit Steuermodul tatsächlich SE enthalten, trifft dies nicht immer zu, was die Aufgabe deutlich erschwert. Gleichzeitig zeigt dies, dass das Modell gezielt relevante Bereiche der Pumpe analysieren kann, ohne dass diese Relation explizit vorgegeben wurde.

Quantitative Evaluation der Modelle

Um die Erkennungsgenauigkeit systematisch zu bewerten, wurden in dieser Studie für alle drei Modellvarianten jeweils die drei oben beschriebenen Leistungskennzahlen gemessen, welche in Abbildung 3 dargestellt sind.

Abbildung 3: Leistungsvergleich der YOLOv11-Modelle Nano, Small und Medium hinsichtlich Präzision, Sensitivität und MDP.



Alle drei Varianten erzielen eine hohe Präzision, wobei die Werte im Bereich von 0,80 bis 0,90 liegen. Dies bestätigt, dass das Modell in den meisten Fällen (80–90 %) korrekt ist, wenn es eine Pumpe als SE-haltig identifiziert. Praktisch gesehen verringert dies Fehldetektionen und verhindert, dass in nachfolgenden Recyclingschritten unnötig Ressourcen für die Verarbeitung nicht SE-haltiger Pumpen aufgewendet werden.

Die Ergebnisse zur Sensitivität, dargestellt in der zweiten Balkengruppe in Abbildung 3, zeigen über die Modellgrößen

hinweg leichte Einbußen gegenüber der Präzision und liegen zwischen 0,7 und 0,8. Während die Mehrheit der relevanten Pumpen erfolgreich erkannt wird, bleiben 20–30 % unerkannt. Diese Fehlerrate ist für die Maximierung der SE-Rückgewinnung von großer Bedeutung und unterstreicht die Notwendigkeit weiterer Optimierungen, um die Vollständigkeit in praxisnahen Anwendungen zu gewährleisten.

Die im dritten Abschnitt von Abbildung 3 dargestellten MDP-Werte zeigen deutlichere Unterschiede zwischen den Modellen. Das Nano-Modell erreicht einen Wert von etwa 0,6, während das Small- und Medium-Modell ungefähr 0,7 erzielen. Da diese Metrik die Leistung über verschiedene Überlappungsschwellen hinweg bewertet, belegen die höheren MDP-Werte der größeren Modelle, dass diese genauere Segmentierungsgrenzen vorhersagen. Dies ist insbesondere in Szenarien wichtig, in denen eine präzise Lokalisierung und Abgrenzung zwischen Instanzen erforderlich sind, etwa bei der robotergestützten Handhabung.

Herausforderungen und Limitationen

Obwohl die YOLO-Modelle eine robuste Leistung bei der Identifikation von Pumpen mit SE zeigten, müssen vor einem industriellen Einsatz noch mehrere Einschränkungen überwunden werden:

Datensatzumfang und -vielfalt: Die größte Einschränkung liegt in der Größe und Vielfalt des Datensatzes. In dieser Studie wurden 72 Originalbilder auf 1.224 Bilder durch Datenaugmentation erweitert. Zwar erhöht die Augmentation die Trainingsmenge, kann jedoch echte Variationen unter realen Bedingungen nicht vollständig ersetzen. Somit stellt der aktuelle Datensatz lediglich einen begrenzten Ausschnitt der Herausforderungen im täglichen Recyclingbetrieb dar. Mit zunehmender Komplexität und Vielfalt der Daten – beispielsweise durch weitere Pumpentypen oder fehlende Komponenten – könnten robustere und komplexere Modellvarianten erforderlich werden, um eine hohe Segmentierungsleistung zu gewährleisten.

Erkennungsprobleme: Die qualitative Analyse zeigte verschiedene Schwierigkeiten auf. Pumpen ohne SE, aber mit sichtbarem Steuerelement, wurden irrtümlich erkannt, während Pumpen mit verdecktem Steuerelement weniger zuverlässig detektiert wurden. Strukturell ähnliche Pumpen, die nebeneinander lagen, wurden teilweise zusammengefasst und kleinere Pumpen oder solche am Bildrand wurden mit geringerer Zuverlässigkeit erkannt. In der Praxis ist es entscheidend, ein Gleichgewicht zwischen Präzision und Sensitivität zu finden. Ein Modell mit hoher Präzision und niedriger Sensitivität erkennt zwar SE-haltige Pumpen korrekt, übersieht jedoch einige, was angeichts steigender Nachfrage nach SE, Importabhängigkeiten und der Wirtschaftlichkeit des Systems problematisch sein könnte. Ein Modell mit hoher Sensitivität, aber niedriger Präzision erkennt fast alle Pumpen und reduziert dadurch Materialverluste erheblich. Dabei werden allerdings auch viele irrelevante Pumpen bearbeitet, was an anderer Stelle zu einem



höheren Aufwand führt. Das optimale Gleichgewicht hängt schließlich davon ab, ob die Minimierung von Materialverlusten oder die Reduktion des betrieblichen Aufwands in den Folgeprozessen im Vordergrund steht.

Betriebliche und wirtschaftliche Überlegungen: Der Schritt vom Labor zur Praxis stellt neue Hürden dar: Staub, Vibratoren und wechselnde Lichtverhältnisse können Kameras beeinträchtigen. Auch wenn Modelle in ersten Tests ausgezeichnete Ergebnisse liefern, ist bei ihrer langfristigen Anwendung in der Praxis häufig mehr Aufwand nötig. KI-Entscheidungen sollten nachvollziehbar und zuverlässig sein, um auch das Vertrauen der Mitarbeitenden zu stärken. Das System erzielt seinen wirtschaftlichen Vorteil erst, wenn der Nutzen aus der Ressourcenrückgewinnung höher ist als die anfallenden Kosten für Hardware, Wartung und Energie.

Zukünftige Arbeit

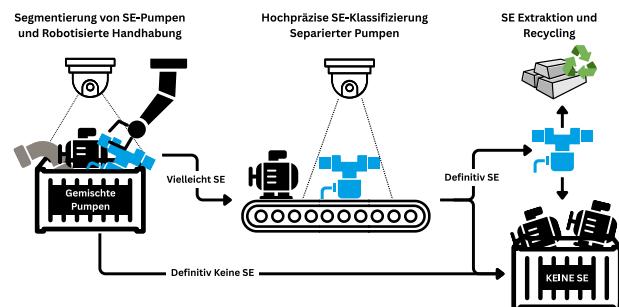
Um die Leistungsfähigkeit der Modelle fundiert zu bewerten und die Arbeit in Richtung eines industriellen Einsatzes bei WILO weiterzuentwickeln, sollten zukünftige Arbeiten auf deutlich größere und vielfältigere Datensätze ausgeweitet werden. Diese Datensätze sollten Bilder umfassen, die unter unterschiedlichen Bedingungen aufgenommen wurden – etwa aus verschiedenen Kamerapositionen und mit einer größeren Vielfalt an Pumpen.

Ebenso ist es von zentraler Bedeutung, sorgfältig zu planen, wie die trainierten Modelle nahtlos und effektiv in eine durchgängige Prozesskette integriert werden können. Hierzu könnten Pilotprojekte direkt im Recyclingcenter durchgeführt werden, bei denen Förderbandsysteme, robotergestützte Handhabung und nachgelagerte Recyclingprozesse einbezogen werden.

Im industriellen Umfeld könnte das KI-System beispielsweise in eine Anlage integriert werden, in der ein Roboterarm erkannte Pumpen auf ein Förderband legt. Da es schwierig ist, alle relevanten Pumpen in einer befüllten Kiste gleichzeitig zu erkennen, sollten zu einem späteren Zeitpunkt zusätzliche Kameras installiert werden, um Einzelaufnahmen für eine hochpräzise Klassifikation zu ermöglichen. Das System würde die Pumpen anschließend je nach SE-Präsenz in die entsprechenden Sammelbehälter sortieren. Abbildung 4 veranschaulicht diese integrierte Prozesskette, die maschinelles Sehen, Robotik und Steuerungssysteme miteinander verbindet.

Beginnend auf der linken Seite erfasst eine Überkopf-Kamera die im Gitterkasten gesammelten Pumpen und segmentiert dabei einzelne Instanzen mit SE-Anteil zur anschließenden Roboterhandhabung. Dies ist das Eingangsszenario, das in der vorliegenden Fallstudie untersucht wurde. Basierend auf den oben genannten Erkenntnissen sollte hierbei ein Modell mit hoher Sensitivität eingesetzt werden, um sicherzustellen, dass möglichst viele SE-haltige Pumpen auf das Förderband gelangen. Im nächsten Schritt erfolgt dann eine erneute Kontrolle jeder einzelnen Pumpe durch ein Modell mit hoher Präzision. Hierbei wird untersucht, ob SE tatsächlich enthalten sind. Pumpen, bei

Abbildung 4: Konzept einer Prozesskette zur Sortierung von SE-Pumpen.



denen diese Annahme verworfen wird, werden in einen separaten Behälter für Pumpen ohne SE umgeleitet, während die bestätigten Pumpen dem speziellen WILO-Recyclingprozess zugeführt werden.

Darüber hinaus würde eine Erweiterung des Systems zur gleichzeitigen Bewertung des Pumpenzustands – zusätzlich zur SE-Erkennung – einen erheblichen Mehrwert für den Betrieb bieten. Durch die Erkennung von Schäden oder Wartungsbedarf könnte WILO gezielt Strategien zur Aufarbeitung und Wiederverwendung von Pumpen verfolgen, insbesondere wenn ein Recycling noch nicht notwendig ist.

Schlusswort

Mit dem weltweit steigenden Bedarf an SE stehen Innovationen wie KI-gestützte Recyclingverfahren für mehr als nur technischen Fortschritt. Sie kennzeichnen eine Entwicklung hin zu industriellen Systemen, in denen technologische Innovation mit einem bewussteren Umgang mit Ressourcen einhergeht. Zwar stellt die KI-basierte visuelle Inspektion allein noch keine vollständige Lösung dar, ist aber eine wichtige Voraussetzung für die Ressourceneffizienz im Recyclingprozess. Diese Machbarkeitsstudie belegt, dass moderne Objekterkennungssysteme Pumpen mit SE-Anteilen zuverlässig erkennen und damit einen spürbaren Mehrwert für die Recyclingprozesse von WILO bieten können.

Weitere Forschung, größere und vielfältigere Datensätze sowie kollaborative Pilotprojekte könnten die Entwicklung KI-basierter Sortieranlagen vorantreiben. Damit würde ein bedeutender Fortschritt in Richtung Kreislaufwirtschaft erzielt, was nicht nur zur Verringerung der Umweltauswirkungen beiträgt, sondern auch die Widerstandsfähigkeit und Nachhaltigkeit der gesamten Lieferkette erhöht.



Literatur

Abou Baker, N. & Handmann, U. (2022). An Approach for Smart and cost-Efficient Automated E-Waste Recycling for Small to medium-Sized Devices Using multi-Sensors. *IEEE Sensors*, 1–4. <https://doi.org/10.1109/sensors52175.2022.9967195>

Díaz, I., Borro, D., Iparraguirre, O., Eizaguirre, M., Ricardo, F. A., Muñoz, N., & Gil, J. J. (2025). Robotic system for automated disassembly of electronic waste: Unscrewing. *Robotics and Computer-Integrated Manufacturing*, 95, 103032. <https://doi.org/10.1016/j.rcim.2025.103032>

Scaife, A. D. (2023). Improve predictive maintenance through the application of artificial intelligence: A systematic review. *Results in Engineering*, 21, 101645. <https://doi.org/10.1016/j.rineng.2023.101645>

Abou Baker, N.; Rohrschneider, D.; Handmann, U. (2022). Battery detection of x-ray images using transfer learning. In *The 30th European Symposium on Artificial Neural Networks (ESANN 2022)*, Bruges, Belgium, pp. 241–246. <https://doi.org/10.14428/esann/2022.ES2022-60>

Abou Baker, N., Rohrschneider, D., & Handmann, U. (2024). Parameter-Efficient Fine-Tuning of large pretrained models for instance segmentation tasks. *Machine Learning and Knowledge Extraction*, 6(4), 2783–2807. <https://doi.org/10.3390/make6040133>

Jocher, G.; Qiu, J. (2024). Ultralytics YOLO11 (Version 11.0.0) [Computer software]. Ultralytics. <https://github.com/ultralytics/ultralytics>

Rohrschneider, D., Abou Baker, N., & Handmann, U. (2023). Double transfer learning to detect Lithium-Ion batteries on X-Ray images. In *Lecture notes in computer science* (pp. 175–188). https://doi.org/10.1007/978-3-031-43085-5_14

Roboflow (2025). Computer vision tools for developers and enterprises. Available at: <https://roboflow.com>. Last accessed 09.10.2025

Reihe

RETHINK. Impulse zur zirkulären Wertschöpfung / Enabling the Circular Economy | Uwe Handmann, Wolfgang Irrek (Hrsg.)
ISSN (Print) 2750-6215 | ISSN (Online) 2750-6223 | 1. Fassung, 30.01.2026
Online abrufbar unter: www.prosperkolleg.ruhr

Impressum / Kontakt

Prosperkolleg e.V.
Gladbecker Straße 19b, 46236 Bottrop
Germany
info@prosperkolleg.ruhr



Dieses Werk ist lizenziert unter einer Creative Commons Namensnennung - Weitergabe unter gleichen Bedingungen 4.0 International Lizenz.

Titelbild: www.unsplash.com, Photo by Ricardo Gomez-Angel, bearbeitet



**Kofinanziert von der
Europäischen Union**

Ministerium für Wirtschaft,
Industrie, Klimaschutz und Energie
des Landes Nordrhein-Westfalen

