Inventurdifferenzen: Der teuerste blinde Fleck des Handels

Wie KI-gestützte Bestandsgenauigkeit Schwund reduziert und Umsatz sichert

codecentric AG | Whitepaper

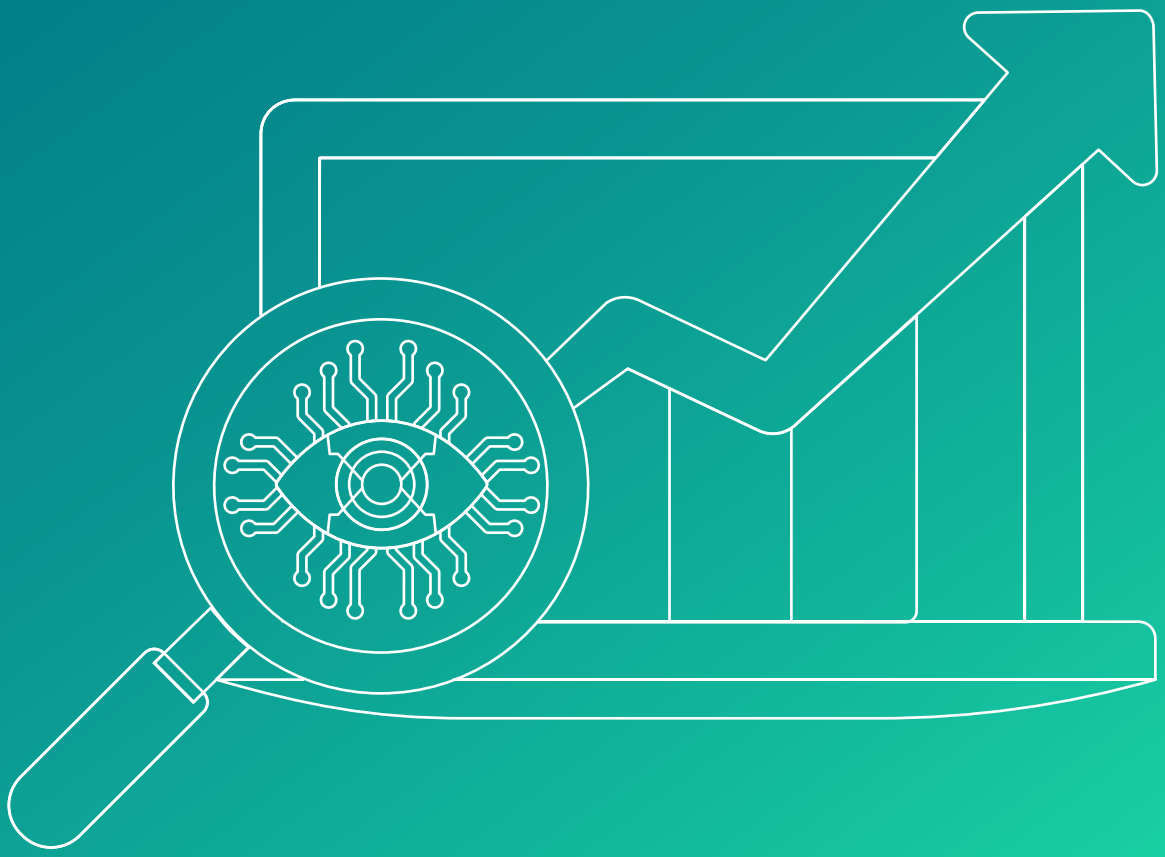

codecentric

Inhaltsverzeichnis

Executive Summary	3
1. Einleitung: Warum Inventurdifferenzen Chefsache sind	4
2. Das Ausmaß des Problems: Inventurdifferenzen in Zahlen	4
3. Ursachenanalyse: Mehr als nur Diebstahl	5
4. Warum klassische Gegenmaßnahmen an ihre Grenzen stoßen	7
5. Der Lösungsansatz: KI-gestützte Bestandsgenauigkeit	8
6. Rechtlicher Rahmen: Was in Deutschland zulässig ist	11
7. Best Practices: Wer setzt was bereits um?	12
8. Wirtschaftlicher Nutzen und ROI	14
9. Vom Piloten zur Skalierung: Ein pragmatischer Einstieg	15
Fazit	17
Über uns | Kontakt	18
Quellenverzeichnis	19

Executive Summary

5,11 Milliarden Euro hat der deutsche Einzelhandel im Jahr 2025 durch Inventurdifferenzen verloren – Tendenz seit Jahren steigend.[1] Diebstahl ist mit rund 85 Prozent der Wertdifferenz die größte Einzelursache, doch er ist bei Weitem nicht die einzige: Rund 15 Prozent der Differenz entstehen durch organisatorische Mängel – Buchungsfehler, fehlerhafte Wareneingänge oder nicht erfasste Retouren.

Das eigentliche Problem liegt tiefer: Der Systembestand vieler Händler stimmt eigentlich nur am Tag der Vollinventur mit der Realität überein. Studien beziffern den Anteil ungenauer Bestandsdatensätze auf SKU-Ebene auf bis zu 60 Prozent.[2, 3] Diese Ungenauigkeit wirkt sich nicht nur auf die jährliche Inventur aus, sondern auf nahezu jeden operativen Prozess: Disposition, Lagerhaltung, Pricing, Demand Forecasting und Omni-Channel.

Klassische Gegenmaßnahmen – Kameras, Warensicherung, mehr Personal – kosten den deutschen Einzelhandel jährlich rund 3,1 Milliarden Euro[1], ändern aber wenig am Grundproblem: 98 Prozent aller Diebstähle bleiben unentdeckt.[1] Gleichzeitig bewerten 100 Prozent der befragten Retail-CIOs in Deutschland künstliche Intelligenz als wichtigsten Zukunftstrend[4] – konkrete Anwendungen zur Bestandsgenauigkeit sind in deutschen Handelsunternehmen jedoch noch die Ausnahme.

Dieses Whitepaper zeigt Entscheiderinnen und Entscheidern mit Umsatzverantwortung, wie KI-gestützte Ansätze wirken: von risikobasiertem Cycle Counting über Anomalieerkennung in Kassendaten bis zu rechtlich zulässigen Vision-Systemen am Self-Checkout. Referenzwerte aus der Praxis zeigen ein Potenzial von 20 bis 40 Prozent Schwundreduktion[5] – bei einem Business Case, der sich in der Regel innerhalb weniger Monate rechnet.

Auf den Punkt

Wer Inventurdifferenzen nachhaltig reduzieren will, muss nicht nur Diebstahl stoppen, sondern vor allem wissen, was tatsächlich im Bestand ist. KI kann hier wertvolle Einblicke liefern: Sie ist stark im Erkennen von Mustern und kann helfen, die wahren Gründe für Inventurdifferenzen aufzudecken.

1. Einleitung: Warum Inventurdifferenzen Chefsache sind

Jeder Einzelhändler kennt seine Inventurdifferenz als Zahl – ob aus der jährlichen Vollinventur oder aus rollierenden Teilzählungen im Rahmen permanenter Inventur. Was ihm in beiden Fällen fehlt, ist eine durchgängige Kenntnis des tatsächlichen Bestands zwischen den einzelnen Zählzeitpunkten. Die Inventur ist eine Stichprobe, die im Moment ihrer Entstehung bereits wieder veraltet: Sobald die Filiale nach der Zählung öffnet, beginnt die Abweichung zwischen Systembestand und Realität von Neuem.

Für Business-Entscheiderinnen und -Entscheider mit direkter Umsatzverantwortung ist das mehr als ein Buchhaltungsthema. Ein ungenauer Bestand wirkt sich unmittelbar auf harte betriebswirtschaftliche Größen aus: auf entgangenen Umsatz durch leere Regale, auf gebundenes Kapital durch Phantom-Bestände, auf Kundenzufriedenheit bei Click & Collect und auf die Marge bei Abschriften verderblicher Ware. Wer die Ursachen von Inventurdifferenzen versteht und gezielt angeht, hebt einen der am besten belegten und am direktesten monetarisierbaren Hebel im gesamten Handelsgeschäft.

Dieses Whitepaper richtet sich in erster Linie an Geschäftsführung, Vertriebs- und Filialverantwortliche sowie Bereichsleitungen mit Ergebnisverantwortung im Einzelhandel; ergänzend auch an IT- und Digitalisierungsverantwortliche, die die technische Umsetzbarkeit einordnen möchten.

Der rote Faden: Zunächst wird das Ausmaß des Problems anhand belastbarer Branchendaten eingeordnet (Kapitel 2). Anschließend zeigt Kapitel 3, dass Inventurdifferenzen zwar mehrheitlich, aber eben nicht ausschließlich auf Diebstahl zurückgehen – organisatorische Mängel sind der Hebel, den Technologie am wirksamsten adressieren kann. Kapitel 4 erklärt, warum klassische Gegenmaßnahmen an ihre Grenzen stoßen, bevor Kapitel 5 den Lösungsansatz der KI-gestützten Bestandsgenauigkeit im Detail vorstellt. Kapitel 6 ordnet die rechtlichen Leitplanken in Deutschland ein, Kapitel 7 zeigt, wer das bereits umsetzt, und die Kapitel 8 und 9 übersetzen das Ganze in wirtschaftlichen Nutzen und einen konkreten Einstiegspfad.

2. Das Ausmaß des Problems: Inventurdifferenzen in Zahlen

2.1 Eine Milliardensumme mit steigender Tendenz

Der deutsche Einzelhandel erwirtschaftete 2025 einen Umsatz von rund 505 Milliarden Euro[1]. Im selben Jahr summierten sich die Inventurdifferenzen – der Wert der Differenz zwischen Soll- und Ist-Bestand, gemessen zu Verkaufspreisen – auf **5,11 Milliarden Euro**, nach 4,95 Milliarden Euro im Jahr zuvor.[1] Das entspricht einem Anstieg von 3,2 % gegenüber einem Umsatzwachstum von nur rund 2 % – die Differenz wächst also schneller als der Umsatz, der sie relativiert.

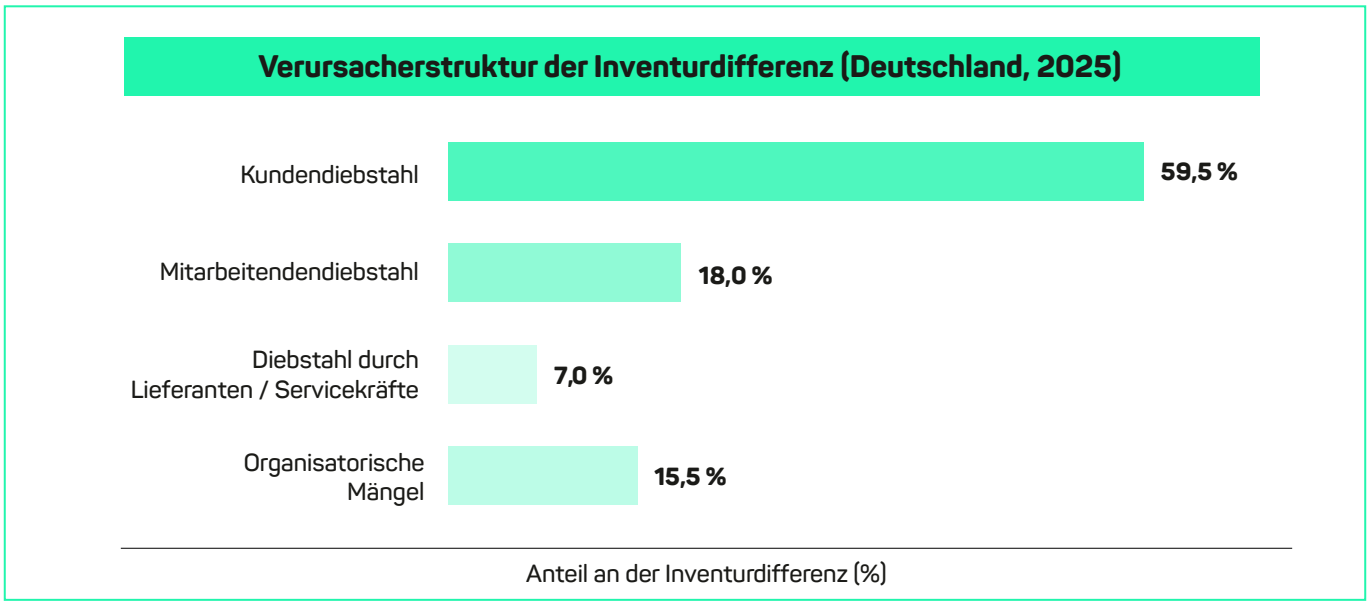

Abb. 1: Verursacherstruktur der Inventurdifferenz in Deutschland, 2025 (Quelle: EHI Retail Institute)

Bewertet zu Einkaufspreisen und ins Verhältnis zum Nettoumsatz gesetzt, ergibt sich eine **Schwundquote von etwa 0,64 %** für den Einzelhandel insgesamt.[1] Im Lebensmitteleinzelhandel (LEH) liegt die Quote für Food-Sortimente mit 0,79 % spürbar darüber, bei Nonfood-Sortimenten mit 0,45 % leicht darunter.[6] Eine Zahl, die auf den ersten Blick klein wirkt – bei einem Umsatz von 1 Milliarde Euro pro Jahr bedeutet aber schon eine Verbesserung um einen einzigen Prozentpunkt bei der Bestandsgenauigkeit hochgerechnet eine Einsparung von 6,85 bis 15 Millionen US-Dollar.[5]

2.2 Self-Checkout als Brandbeschleuniger

Ein struktureller Trend verschärft das Problem zusätzlich: die rasante Verbreitung von Self-Checkout-Kassen (SCO). In Deutschland stehen inzwischen rund 38.650 Selbstbedienungskassen, davon etwa 25.000 im Lebensmitteleinzelhandel – jede 18. Kasse im deutschen Einzelhandel ist mittlerweile eine SB-Kasse.[7] Die Zahl der Geschäfte mit SCO hat sich innerhalb von zwei Jahren um 143 % erhöht.[7]

Der Effekt auf die Schwundrate ist erheblich: An bemannten Kassen liegt sie bei rund 0,2 %, an Selbstbedienungskassen bei rund 3,5 % – das **17-Fache**[7]. Der Grund liegt weniger in vorsätzlichem Betrug als in der Mechanik des Prozesses: Fehlscans, falsch zugeordnete Warengruppen, „Luftretouren" oder schlicht vergessene Artikel passieren an der Selbstbedienungskasse häufiger als unter der Aufsicht von Kassenpersonal.

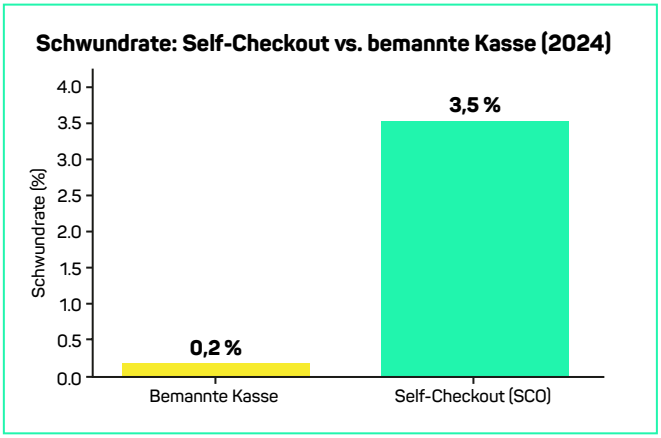

Abb. 2: Schwundrate Self-Checkout vs. bemannte Kasse, 2024 (Quelle: EHI Retail Institute)

Eine aktuelle Studie von ECR Retail Loss und der University of Leicester mit 39 Handelsunternehmen und über 1 Billion Euro gemeinsamem Jahresumsatz bestätigt diesen Befund für 2026 in großem Maßstab: Der Schwund steigt im ersten Jahr nach SCO-Einführung im Schnitt um 22 %, wobei der überwiegende Teil der Fälle auf Fehlscans und liegengelassene Artikel statt auf vorsätzlichen Diebstahl zurückgeht (Quelle: ECR Retail Loss / University of Leicester, „Self-Checkout Loss Report 2026").

2.3 Der globale Kontext

Deutschland steht mit diesem Problem nicht allein da. Die IHL Group beziffert die weltweiten Kosten von Bestandsverzerrungen – der Summe aus Out-of-Stock- und Überbestandskosten – für 2025 auf **1,73 Billionen US-Dollar**[8], trotz Investitionen von 172 Milliarden US-Dollar in Verbesserungsmaßnahmen im Jahr zuvor. Organisierte Kriminalität und Diebstahl allein summieren sich global auf rund 379 Milliarden US-Dollar.[8]

Bemerkenswert ist ein zweiter Befund derselben Studie: Handelsunternehmen, die KI und maschinelles Lernen aktiv in ihrer Bestandssteuerung einsetzen, verzeichnen ein 2,3-fach höheres Umsatzwachstum und ein 2,5-fach höheres Gewinnwachstum als Wettbewerber, die auf traditionelle Methoden setzen.[8] Die Studie spricht in diesem Zusammenhang von einer Spaltung zwischen „AI Haves" und „AI Have-nots" – einer Kluft, die sich in den kommenden Jahren voraussichtlich vergrößert.

2.4 Warum diese Zahlen für Entscheider relevant sind

- **Direkte Ergebniswirkung:** Inventurdifferenzen mindern die Marge unmittelbar und sind, anders als viele andere Digitalisierungsthemen, in Euro und Cent nachvollziehbar.
- **Wachsende Dringlichkeit:** Die Differenz wächst schneller als der Umsatz – ohne Gegenmaßnahmen verschärft sich das Problem strukturell weiter.
- **Technologischer Rückstand als Chance:** Weil der deutsche Einzelhandel bei datengetriebener Bestandsgenauigkeit noch am Anfang steht, ist der Hebel für Unternehmen, die früh investieren, besonders groß.

3. Ursachenanalyse: Mehr als nur Diebstahl

Diebstahl ist die größte Einzelursache für Inventurdifferenzen – daran besteht kein Zweifel. Kundendiebstahl allein verursacht rund 59,5 % der Wertdifferenz (etwa 3,05 Milliarden Euro), Mit-

arbeitendendiebstahl weitere 18 % (rund 910 Millionen Euro) und Diebstahl durch Lieferanten oder externe Servicekräfte rund 7 % (etwa 370 Millionen Euro).[1] In Summe gehen damit rund 85 % der deutschen Inventurdifferenz auf Diebstahl in seinen verschiedenen Formen zurück.

Für Entscheiderinnen und Entscheider ist jedoch der zweite Teil der Zahl mindestens ebenso wichtig: Rund **15 % der Differenz – etwa 780 Millionen Euro – entstehen durch organisatorische Mängel**[1]: fehlerhafte Wareneingangsbuchungen, nicht erfasste Retouren, Verderb, der nicht ausgebucht wird, Stammdatenfehler und schlicht falsch konfigurierte Scanner. Diese Differenz ist kein Randphänomen. Bei einem Gesamtvolumen von 5,11 Milliarden Euro sind 780 Millionen Euro eine Summe, die jedes Unternehmen für sich genommen ernst nehmen sollte.

Warum diese Unterscheidung wichtig ist

Diebstahlprävention ist aktuell überwiegend eine physische und rechtliche Aufgabe – Kameras, Personal, Zugangskontrollen, mit engen rechtlichen Grenzen (siehe Kapitel 6). Organisatorische Mängel dagegen sind ein Datenproblem: Sie entstehen dort, wo Systeme nicht miteinander sprechen oder Prozesse nicht sauber abgebildet werden. Genau dieses Problem lässt sich mit KI und Datenanalyse direkt adressieren, unabhängig von den rechtlichen Einschränkungen, die für personenbezogene Videoüberwachung gelten.

3.1 Das eigentliche Problem: Bestandsdaten, die nicht stimmen

Hinter beiden Ursachengruppen – Diebstahl wie organisatorischen Mängeln – steht ein gemeinsames strukturelles Problem: Der Systembestand vieler Händler stimmt an den meisten Tagen des Jahres nicht mit der Realität überein. Eine Studie der Harvard Business School aus dem Jahr 2008 zeigte, dass 35 bis 65 % der Bestandsdatensätze auf SKU-Ebene von der Realität abweichen.[2] Aktuellere Branchenzahlen der ECR Community bestätigen die Größenordnung mit rund 60 % ungenauen Records im Lebensmittel- und FMCG-Handel.[3] Jede zweite bis dritte Bestandsposition im System ist mit anderen Worten falsch – ein Zustand, der seit über anderthalb Jahrzehnten dokumentiert ist und sich durch Self-Checkout, Omnichannel-Vertrieb und wachsende Sortimentskomplexität eher verschärft als verbessert hat.

Diese Ungenauigkeit hat zwei Richtungen, die betriebswirtschaftlich unterschiedlich schwer wiegen: Phantom-Bestand und Hidden Inventory (s. Abb. 3).

Phantom-Bestände sind laut Zebra Technologies für rund 8 % aller Bestandsverluste verantwortlich.[9] Ihre eigentliche Wirkung entfaltet sich jedoch indirekt: Die europäische Out-of-Stock-Rate im Lebensmitteleinzelhandel liegt bei 7 bis 8 % – und rund die Hälfte dieser Regallücken ist nicht auf Lieferengpässe, sondern auf fehlerhafte Bestandsdaten zurückzuführen.[3] Das Regal ist leer, obwohl das System „vorhanden" meldet.

3.2 Wo im Prozess die Differenzen entstehen

Ein Blick auf die Kernprozesse des Lebensmitteleinzelhandels zeigt, dass die Prozesse mit dem höchsten monetären Durchsatz gleichzeitig die fehleranfälligsten sind (s. Abb. 4).

Bemerkenswert ist die Rolle der Disposition: Sie erzeugt selbst keine Bestandsdifferenz, verstärkt aber jede bestehende Abweichung, weil sie permanent auf Basis der im Schnitt zu 60 % fehlerhaften Systembestände entscheidet, was nachbestellt wird. Ein Prozess, der rechnerisch mit 0 % direktem Risiko geführt wird, kann so zum größten Hebel für Folgekosten werden.

Auch beim Wareneingang pflanzen sich Fehler fort: Falsche Mengen, beschädigte Ware oder fehlerhafte Reklamationsbuchungen wirken sich auf alle nachgelagerten Prozesse aus. Und weil POS-, ERP-, Warenwirtschafts- und Lagerverwaltungssysteme in den meisten Handelsunternehmen als isolierte Systeminseln arbeiten – häufig noch über Excel-Tabellen notdürftig verbunden –, bleiben solche Fehler oft unentdeckt, bis die Jahresinventur sie kumuliert sichtbar macht.[10]

Komponente	Richtung	Bedeutung
Phantom-Bestand	System > Real	System meldet Ware, die physisch fehlt. Das führt zu leeren Regalen trotz „Bestand vorhanden", Fehldisposition und gescheiterten Click & Collect-Bestellungen. Die teuerste Fehlerkategorie
Hidden Inventory	Real > System	Ware ist physisch da, das System weiß nichts davon. Das führt zu Überbestand, unnötiger Kapitalbindung und überflüssigen Nachbestellungen. Es ist weniger schädlich als Phantom-Bestand, aber ebenfalls kostenwirksam.

Abb. 3: Richtung von Bestandsungenauigkeiten (Quelle: Zebra Technologies; RELEX Solutions; eigene Darstellung)

Prozess	Monetärer Wert	Differenz-Risiko	Anteil an Differenzen
Verkauf / Kassiervorgang	Höchster	Sehr hoch, steigend	~65–70 %
Lager / Regalpflege	Hoch	Sehr hoch	Teil der 15 % org. Mängel
Wareneingang	Mittel	Hoch	~7 %
Disposition	Sehr hoch	0 % direkt, massiv indirekt	–
Rechnungsprüfung	Hoch (administrativ)	Gering direkt, mittel indirekt	–
Marketing / Aktionssteuerung	Mittel	Mittel	Teil der 15 % org. Mängel

Abb. 4: Ursachen für Differenzen (Quelle: EHI Retail Institute / handelsdaten.de, Studie „Inventurdifferenzen 2026"; eigene Auswertung)

3.3 Fazit: Ein differenziertes Bild als Grundlage für gezieltes Handeln

- **Diebstahl bleibt die größte Ursache** (~85 %) und muss adressiert werden – mit den rechtlich zulässigen Mitteln, die Kapitel 6 einordnet.
- **Organisatorische Mängel** (~15 % bzw. 780 Millionen Euro) sind zahlenmäßig kleiner, aber technologisch der am direktesten adressierbare Hebel – ohne die rechtlichen Restriktionen personenbezogener Überwachung.
- **Beide Ursachengruppen wurzeln im selben Grundproblem:** einem Systembestand, der der Realität permanent hinterherhinkt. Wer dieses Grundproblem löst, verbessert nicht nur die Inventurdifferenz, sondern die Datenqualität für Disposition, Forecasting und Omnichannel gleichermaßen.

4. Warum klassische Gegenmaßnahmen an ihre Grenzen stoßen

Der deutsche Einzelhandel ist beim Thema Schwund nicht untätig. Rund 1,7 Milliarden Euro – etwa 0,33 % des Umsatzes – fließen jährlich in klassische Präventionsmaßnahmen: Kameras, Warensicherungsetiketten, Detektive, Schulungen.[1] Rechnet man interne Aufwände wie Bestandskontrollen, manuelle Datenanalysen und die Bearbeitung von Diebstahlanzeigen hinzu, steigen die Gesamtkosten auf rund 3,1 Milliarden Euro.[1]

Das Ergebnis dieser Investitionen ist ernüchternd: **98 % aller Diebstähle bleiben unentdeckt**[1] – das entspricht schätzungsweise rund 24,5 Millionen Fällen pro Jahr allein in Deutschland. Klassische Prävention wirkt, aber sie wirkt an der falschen Stelle: reaktiv, physisch und auf den Moment der Tat fokussiert, statt auf das zugrunde liegende Datenproblem.

4.1 Drei strukturelle Grenzen klassischer Maßnahmen

Grenze 1: Physische Prävention löst kein Datenproblem

Kameras und Warensicherung reduzieren Gelegenheiten für Diebstahl, aber sie schaffen keine Transparenz darüber, wo im Bestand Differenzen entstehen. Ein Retailer, der nach einer erfolgreichen Kamera-Installation nicht misst, ob und wo sich seine Inventurdifferenz tatsächlich verändert, arbeitet weiterhin blind gegenüber Phantom-Beständen, Fehlbuchungen und Prozessfehlern – also gegenüber den rund 15 % der Differenz, die überhaupt nicht auf Diebstahl zurückgehen.

Grenze 2: Statische Zählpläne verschwenden Ressourcen

Der Gesetzgeber verpflichtet Handelsunternehmen, jeden Artikel mindestens einmal jährlich zu zählen (Inventurpflicht nach § 240 HGB). Die Möglichkeit der permanenten Inventur (im Gegensatz zur Stichtagsinventur) wird bislang weit seltener angewendet, obwohl der Gesetzgeber diese Ausführung erlaubt (§ 241 HGB). Dabei lohnt sich der Ansatz der permanenten Inventur vor allem bei besonders breiten oder tiefen Sortimenten, wie sie in Supermärkten, Discountern oder Baumärkten zu finden sind. In der Praxis bedeutet das meist starre, gleichmäßig über das Sortiment verteilte Zählpläne – unabhängig davon, ob ein Artikel hochpreisig und diebstahlgefährdet oder ein margenschwacher Langsamdreher ist. Schätzungen gehen davon aus, dass **80 bis 90 % aller**

Zählungen keinen belastbaren Mehrwert liefern[10] – weil sie Artikel betreffen, bei denen ohnehin kaum Abweichungen zu erwarten sind, während echte Risikoartikel nicht häufiger geprüft werden als der Rest des Sortiments.

Grenze 3: Isolierte Systeme verhindern Mustererkennung

In den meisten Handelsunternehmen arbeiten Kassensysteme (POS), Warenwirtschaft, ERP und Lagerverwaltung als getrennte Systeminseln.[10] Zusammenhänge zwischen Warenplatzierung, Schwundmustern und Verkaufsverhalten sind dem Personal auf der Fläche oft implizit bekannt, aber in den Daten unsichtbar, weil niemand sie systemübergreifend zusammenführt. Ein falsch konfigurierter Scanner in einer einzelnen Filiale kann über Monate hinweg Tausende Euro Phantomschwund erzeugen, ohne dass es auffällt – schlicht weil kein System die Diskrepanz zwischen erwartetem und tatsächlichem Warenfluss automatisiert markiert.

4.2 Die Lücke zwischen Rechtsunsicherheit und technischer Reife

Ein zusätzliches Hemmnis ist spezifisch für Deutschland: Bei kamerabasierten KI-Ansätzen zur Diebstahlprävention sorgt die Rechtslage für erhebliche Unsicherheit. Laut einer DIHK/ibi-Research-Studie werden Pilotprojekte zur KI-gestützten Überwachung in Deutschland „oft abgebrochen oder gar nicht gestartet", während in anderen EU-Ländern mit weniger restriktiver DSGVO-Auslegung bereits Praxistests laufen.[11] Kapitel 6 ordnet diesen Rahmen im Detail ein – wichtig an dieser Stelle ist die Konsequenz: Ansätze, die auf Datenanalyse statt auf Personenüberwachung setzen, unterliegen diesen Restriktionen nicht in gleichem Maße und sind entsprechend schneller und risikoärmer umsetzbar.

Die Grundspannung

Der deutsche Handel investiert vor allem in physische, reaktive Prävention, während 100 % der befragten Retail-CIOs künstliche Intelligenz als wichtigsten Zukunftstrend einstufen. Zwischen dieser Einschätzung und der tatsächlichen Umsetzung bei der Bestandsgenauigkeit klafft eine deutliche Lücke.

Diese Lücke ist der Ausgangspunkt für den in Kapitel 5 vorgestellten Lösungsansatz: Statt zusätzliches Geld in weitere physische Sicherungsmaßnahmen zu investieren, setzt KI-gestützte Bestandsgenauigkeit dort an, wo der größte ungenutzte Hebel liegt – bei den Daten, die bereits heute in den Systemen der Handelsunternehmen vorhanden sind, aber nicht zusammengeführt und ausgewertet werden.

5. Der Lösungsansatz: KI-gestützte Bestandsgenauigkeit

Der rote Faden aus den vorangegangenen Kapiteln lässt sich in einem Satz zusammenfassen: Wer Inventurdifferenzen nachhaltig reduzieren will, muss zuerst wissen, was tatsächlich im Bestand ist. Alles andere – automatisierte Disposition, Dynamic Pricing, verlässliche Click-&-Collect-Angebote – baut auf dieser Grundlage auf. Dieses Kapitel stellt fünf KI-gestützte Bausteine vor, die genau hier ansetzen: von der Diagnose (Mismatch Risk Score) über die gezielte Kontrolle (risikobasiertes Cycle Counting) bis zur operativen Nutzung sauberer Bestandsdaten (Disposition, Pricing, Vision am Self-Checkout).

5.1 Die Grundlage: Datenzusammenführung und Mismatch Risk Score

In den meisten Handelsunternehmen arbeiten Kassensysteme, Warenwirtschaft, ERP und Lagerverwaltung als isolierte Systeminseln, die häufig noch über Excel-Tabellen notdürftig verbunden werden. Zusammenhänge zwischen Warenplatzierung, Schwundmustern und Verkaufsverhalten sind dem Filialpersonal oft implizit bekannt, aber in den Daten unsichtbar.

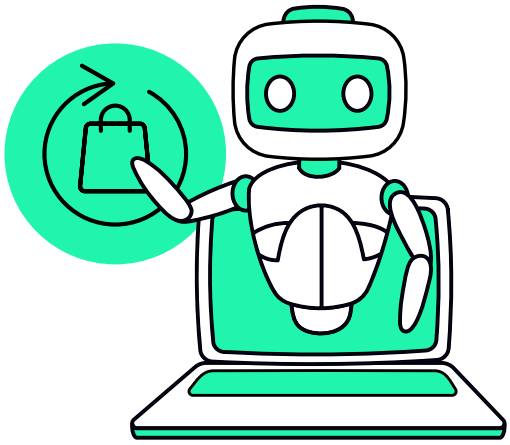

Der erste und wichtigste Schritt ist daher unspektakulär, aber entscheidend: die Zusammenführung der vorhandenen Daten aus POS, ERP, Warenwirtschaft und Lagerverwaltung in einer gemeinsamen Sicht. Erst auf dieser Basis lässt sich ein **Mismatch Risk Score** berechnen – ein dynamischer Risikowert pro Artikel und Filiale, der mehrere Signale kombiniert:

- **Verkaufsverhalten:** Ungewöhnliche Abweichungen vom erwarteten Abverkaufsmuster
- **Wareneingang vs. Abverkauf:** Diskrepanzen zwischen gebuchtem Zugang und tatsächlichem Verkauf
- **Retouren und Stornos:** Auffällige Häufungen, die auf Prozessfehler oder Manipulation hindeuten können
- **Historische Abweichungen:** Artikel und Filialen mit wiederkehrenden Differenzen in der Vergangenheit
- **Zeit seit letzter Zählung:** Je länger eine Zählung zurückliegt, desto unsicherer die Datenbasis

Was ist der Mismatch Risk Score?

Der Mismatch Risk Score ist ein KI-berechneter, dynamischer Kennwert pro Artikel und Filiale, der angibt, wie wahrscheinlich eine Abweichung zwischen Systembestand und tatsächlichem Bestand ist. Er wird fortlaufend aus mehreren Datensignalen aktualisiert – etwa Verkaufsverhalten, Diskrepanzen zwischen Wareneingang und Abverkauf, Retouren sowie der Zeit seit der letzten Zählung – und dient als Grundlage für risikobasiertes Cycle Counting (Kapitel 5.2), für die Priorisierung von Prüfungen und auch für vorbeugende Maßnahmen wie eine risikoorientierte Warenplatzierung.

Die KI-Komponente liegt dabei nicht im Ersetzen menschlicher Erfahrung, sondern in der Anomalieerkennung: Das System lernt aus historischen Mustern, welche Signalkombinationen auf echte Bestandsfehler hindeuten und welche auf normale Schwankungen zurückzuführen sind. Entscheidend für die Akzeptanz im Tagesgeschäft ist dabei, dass jeder Score erklärbar bleibt und sich auf seine Treiber zurückführen lässt – „Black-Box"-Entscheidungen untergraben das Vertrauen von Fachabteilungen und Filialpersonal.

Über die Nutzung für Zählpriorisierung und Disposition hinaus lässt sich der Mismatch Risk Score auch präventiv einsetzen: Artikel mit dauerhaft hohem Risikowert – etwa besonders diebstahlgefährdete Produkte in bestimmten Filialen – lassen sich gezielt anders platzieren, etwa näher am Kassen- oder Servicebereich, in besser einsehbaren Regalzonen oder mit zusätzlicher Sicherung.

5.2 Risikobasiertes Cycle Counting

Auf Basis des Mismatch Risk Scores lässt sich das gesetzlich vorgeschriebene Zählen – jeder Artikel muss mindestens einmal jährlich gezählt werden – grundlegend neu organisieren. Statt eines starren, gleichmäßig über das Sortiment verteilten Zählplans werden Artikel und Filialen mit hohem Risikowert häufiger geprüft, unkritische Artikel entsprechend seltener.

Der Effekt ist doppelt positiv: Weil schätzungsweise 80 bis 90 % aller heutigen Zählungen keinen belastbaren Mehrwert liefern[10] – reale Bestandsfehler verteilen sich nicht gleichmäßig über das Sortiment, sondern konzentrieren sich auf wenige Risikoartikel –, sinkt der manuelle Zählaufwand insgesamt spürbar – während gleichzeitig die Trefferquote bei tatsächlich risikobehafteten Artikeln steigt. Für die Filiale bedeutet das: weniger gebundene Personalzeit bei gleichzeitig präziseren Bestandsdaten.

Praxisrelevanz für den LEH

Der Lebensmitteleinzelhandel bewertet sein eigenes Inventurergebnis im EHI-Branchenvergleich mit 3,76 von 5 Punkten – die schlechteste Bewertung aller untersuchten Branchen. Risikobasiertes Cycle Counting adressiert genau diesen Schwachpunkt, ohne zusätzliches Personal zu binden.

5.3 Nachfrageprognose und automatisierte Disposition

Saubere Bestandsdaten sind die Voraussetzung für verlässliches Demand Forecasting. Disposition, die auf einem im Schnitt zu rund 60 % fehlerhaften Systembestand aufsetzt, kann selbst mit dem besten Prognosemodell keine verlässlichen Ergebnisse liefern. Erst korrigierte Bestandsdaten machen Machine-Learning-(ML-)basierte Nachfrageprognosen aussagekräftig.

Der Nutzen ist in der Praxis bereits belegt: McKinsey zeigt für ML-basierte Frische-Disposition im Lebensmitteleinzelhandel ein Potenzial von **bis zu 80 % weniger Out-of-Stock-Situationen, über 10 % weniger Abschriften und bis zu 9 % höhere Bruttomarge.**[12] Die ECR Community beziffert den Effekt korrigierter Bestandsdatensätze auf 4 bis 8 % zusätzlichen Umsatz.[3]

Auf dieser Grundlage lässt sich die operative Disposition schrittweise automatisieren: KI-Agenten überwachen Bestände in Echtzeit, erkennen aufkommende Engpässe und lösen Nachschub innerhalb vordefinierter Regeln – Mindest- und Sicherheitsbestände, Lieferantenpräferenzen, Budgetgrenzen, Bestellzyklen – eigenständig aus. Die Kontrolle bleibt dabei beim Handelsunternehmen: Routineentscheidungen laufen automatisiert, strategische Eingriffe bleiben Sache der Disponentinnen und Disponenten.

5.4 Dynamic Pricing für verderbliche Ware

Verderbliche Ware, hohe Lagerkosten und starre Preisstrukturen führen unweigerlich zu Abschriften. KI-gestütztes Dynamic Pricing berechnet auf Basis von Nachfrage, aktuellem Bestand und Mindesthaltbarkeitsdatum automatisch den wirtschaftlich sinnvollen Preis zu jedem Zeitpunkt – artikel- und situationsgenau statt pauschal.

Auch hier gilt: Die Qualität der Preisentscheidung hängt unmittelbar von der Qualität der zugrunde liegenden Bestandsdaten ab. Nur wer den tatsächlichen Bestand und das reale Abverkaufstempo eines Artikels kennt, kann den Preis so weit senken, dass ein Artikel verkauft statt abgeschrieben wird – ohne Marge zu verschenken, die sich bei rechtzeitigerer Steuerung noch hätte realisieren lassen.

Das Ausmaß von Abschriften durch Bruch und Verderb ist dabei beträchtlich: Branchenübergreifend liegt ihr Anteil im Schnitt bei 0,21 % des Umsatzes (Spannweite 0,01 bis 2,80 %), im Lebensmitteleinzelhandel mit durchschnittlich 1,46 % des Umsatzes deutlich darüber (EHI Retail Institute, 2025). Hinzu kommt ein Effekt, der in dieser Zahl nicht sichtbar wird: Der personelle Aufwand, den Filialen heute in die Vermeidung von Abschriften investieren – etwa durch häufigere Anlieferung, engmaschige Sortimentsrotation oder manuelle Kontrolle von Mindesthaltbarkeitsdaten –, verursacht zusätzliche Kosten, die in den reinen Abschriftszahlen nicht erfasst sind. KI-gestütztes Dynamic Pricing reduziert damit nicht nur die Abschriften selbst, sondern auch den Personalaufwand, der heute in ihre manuelle Vermeidung fließt.

5.5 KI-Vision am Self-Checkout: Der rechtlich unbedenkliche Hebel

Self-Checkout-Kassen sind, wie Kapitel 2 gezeigt hat, mit einer 17-fach höheren Schwundrate der größte Einzelverstärker der Inventurdifferenz. Sie sind gleichzeitig der Ort, an dem KI-gestützte Vision-Systeme den größten rechtlichen Spielraum haben, weil sich transaktionsbezogene Prüfungen von personenbezogener Überwachung klar abgrenzen lassen (siehe Kapitel 6 für die rechtliche Einordnung im Detail).

Konkret haben sich international mehrere Anwendungsmuster etabliert, die die Ware bzw. die Transaktion und nicht die Person analysieren:

- **Artikelerkennung / Barcode-Verifikation:** Eine Kamera prüft, ob der gescannte Barcode mit dem physisch erkannten Artikel übereinstimmt, und erkennt so „Barcode Swapping" (z. B. ein günstiger Code auf einem teureren Produkt) und Skip-Scanning.
- **Gewichtsbasierte Plausibilitätsprüfung:** Ein Sensor gleicht das erwartete Gewicht der gescannten Artikel mit dem tatsächlichen Korbgewicht ab – ganz ohne Bildverarbeitung.
- **Exit-Gate-Verifikation:** Ein Scanner am Ausgang liest die Quittung, eine Kamera verifiziert den Warenkorbinhalt – funktional vergleichbar mit einer klassischen Kassenkontrolle, nur automatisiert. Wo aus Kapazitätsgründen nicht jede Transaktion

kontrolliert werden kann, lässt sich die Auswahl mit dem in Kapitel 5.1 vorgestellten Mismatch Risk Score steuern: Statt zufälliger Stichproben werden gezielt Transaktionen mit besonders risikobehafteten Artikeln oder auffälligen Scan-Mustern geprüft – dieselbe Logik, die in Kapitel 5.2 bereits für die Zählpriorisierung genutzt wird, angewendet auf die Ausgangskontrolle.

International zeigen sich hier belastbare Ergebnisse: Anbieter wie Everseen sind nach eigenen Angaben in mehr als 8.600 Filialen von Handelsunternehmen wie Walmart, Costco, Kroger, ASDA und Tesco im Einsatz.[13] Der französische Handelskonzern Intermarché konnte mit einer vergleichbaren Lösung von SeeChange die Fraud-Rate am Self-Checkout von rund 3 % auf unter 1 % senken.[14] In Deutschland setzen unter anderem REWE, IKEA Deutschland und EDEKA bereits vergleichbare, transaktionsbezogene KI-Systeme am Self-Checkout ein (siehe Kapitel 7 für Details zu diesen Praxisbeispielen).

Warum dieser Baustein besonders anschlussfähig ist

KI-Vision am Self-Checkout zielt direkt auf Diebstahlprävention statt auf organisatorische Bestandsgenauigkeit ab. Er lässt sich aber ausdrücklich ergänzend zu den datengetriebenen Bausteinen 5.1 bis 5.4 einsetzen, ohne mit ihnen zu konkurrieren – und ist rechtlich der am wenigsten voraussetzungsreiche Einstiegspunkt in KI-gestützte Loss Prevention.

6. Rechtlicher Rahmen: Was in Deutschland zulässig ist

Wer KI-gestützte Ansätze zur Reduktion von Inventurdifferenzen einführen will, bewegt sich in Deutschland in einem klar umrissenen, aber nicht immer intuitiven rechtlichen Korridor. Dieses Kapitel ordnet die wichtigsten Leitplanken kompakt ein – ohne Anspruch auf eine vollständige juristische Prüfung, die im Einzelfall stets erforderlich bleibt.

6.1 Datenschutz: DSGVO und die Rolle der Videoüberwachung

Videoüberwachung auf der Verkaufsfläche ist in Deutschland grundsätzlich zulässig, gestützt auf Art. 6 Abs. 1 lit. f DSGVO (berechtigtes Interesse am Diebstahlschutz). Die Orientierungshilfe der Datenschutzkonferenz (DSK) zur Videoüberwachung bestätigt dies für den Einzelhandel explizit.[15] Entscheidend ist stets eine Verhältnismäßigkeitsprüfung im Einzelfall, bei der unter anderem eine Rolle spielt, ob die Überwachung anlassbezogen oder anlasslos erfolgt, zeitlich begrenzt oder dauerhaft ist, ob eine reine Momentaufnahme oder eine dauerhafte Speicherung stattfindet und ob personenbezogenes Tracking oder Profiling im Spiel ist.

Drei Punkte verdienen besondere Aufmerksamkeit für KI-Anwendungen:

- **Biometrische Daten:** Gesichtserkennung zur Identifikation einer Person fällt unter Art. 9 DSGVO und ist praktisch nur mit ausdrücklicher Einwilligung jeder betroffenen Person zulässig – im stationären Handel mit Laufkundschaft ist das faktisch nicht umsetzbar.
- **Speicherdauer:** Aufsichtsbehörden nennen 48 bis 72 Stunden als Richtwert; eine längere Speicherung ist nur bei einem konkreten Vorfall zur Beweissicherung vertretbar.
- **Automatisierte Entscheidungen:** Art. 22 DSGVO untersagt vollautomatisierte Entscheidungen mit rechtlicher Wirkung. Ein KI-Alarm, der etwa automatisch eine Personensperre auslöst, erfordert eine menschliche Überprüfung im Loop.

6.2 Der EU AI Act: Eine wichtige Differenzierung

Der EU AI Act ist seit August 2024 in Kraft und wird stufenweise anwendbar. Für den Einzelhandel relevant sind vor allem die in Art. 5 AI Act verbotenen KI-Praktiken. Hier lohnt sich eine genaue Betrachtung, da die öffentliche Diskussion die Reichweite des Verbots teilweise zu weit fasst:

- **Biometrische Echtzeit-Fernidentifizierung** in öffentlich zugänglichen Räumen ist nach Art. 5 Abs. 1 lit. h AI Act verboten – dieses Verbot ist jedoch auf den Einsatz durch Strafverfolgungsbehörden zugeschnitten. Für kommerzielle Betreiber wie Handelsunternehmen ergibt sich die zentrale Beschränkung für Gesichtserkennung zur Identifikation in der Praxis primär aus Art. 9 DSGVO (siehe oben), nicht unmittelbar aus dieser AI-Act-Vorschrift.
- **Biometrische Kategorisierung** (z. B. die Ableitung von Merkmalen wie ethnischer Herkunft oder sexueller Orientierung aus biometrischen Daten) ist nach Art. 5 Abs. 1 lit. g AI Act verboten.
- **Emotionserkennung am Arbeitsplatz** ist nach Art. 5 Abs. 1 lit. f AI Act verboten – ein Verbot, das sich auf den Beschäftigungskontext bezieht und nicht pauschal jede Form der Emotions-

analyse gegenüber Kundschaft erfasst, auch wenn Letztere aus Datenschutz- und Reputationsgründen ebenfalls kritisch zu bewerten ist.

Im Ergebnis bedeutet das: Kommerzielle Gesichtserkennung zur Kundenidentifikation im Handel bleibt praktisch ausgeschlossen – aber in erster Linie wegen der DSGVO-Hürde, nicht allein wegen des AI Act. Für Handelsunternehmen ist diese Differenzierung mehr als juristische Feinheit: Sie zeigt, dass die rechtliche Blockade nicht branchenspezifisch für den Handel geschaffen wurde, sondern aus dem allgemeinen Datenschutzrecht folgt – und dass eng gefasste, transaktionsbezogene Anwendungen (siehe unten) davon unberührt bleiben.

6.3 Praktische Einordnung: Was zulässig ist – und was nicht

Abb. 5 erklärt, warum die in Kapitel 5.5 vorgestellten Vision-Systeme am Self-Checkout rechtlich so attraktiv sind: Sie prüfen die Übereinstimmung von Ware und Scan-Vorgang, nicht das Verhalten einer identifizierten Person. Eine aktuelle DIHK/ibi-Research-Studie bestätigt, dass genau diese rechtliche Unsicherheit bei personenbezogenen Ansätzen viele deutsche Pilotprojekte zur KI-gestützten Überwachung ausbremst oder verhindert[11], während transaktionsbezogene Systeme diesen Konflikt von vornherein vermeiden.

7. Best Practices: Wer setzt was bereits um?

KI-gestützte Ansätze zur Bestandsgenauigkeit und Diebstahlprävention sind kein theoretisches Konzept. National wie international lassen sich bereits produktive Anwendungen beobachten – mit deutlich unterschiedlicher Reife zwischen Deutschland und internationalen Märkten.

7.1 Deutschland: Erste konkrete Schritte, vorsichtiger als international

Unter den deutschen Handelsunternehmen ist **REWE** derzeit am breitesten aufgestellt. Laut Medienberichten und einer dpa-Umfrage nutzt REWE mehrere KI-Systeme parallel: eine visionbasierte Obst- und Gemüseerkennung am Self-Checkout, ein System zur Kassenwarteschlangenerkennung ohne Gesichtserkennung sowie KI-gestützte Analyse des Scan-Verhaltens an SB-Kassen, die Personal bei Auffälligkeiten wie vertauschten Barcodes informiert.[16]

Auch **IKEA Deutschland** setzt laut übereinstimmenden Presseberichten KI an Selbstbedienungskassen ein, um Fehlscans zu erkennen (etwa wenn eine Schranktür gescannt wird, aber der zugehörige Korpus fehlt) – der Rollout soll alle 54 deutschen Filialen umfassen.[17] Laut derselben dpa-Umfrage testet oder nutzt auch **Rossmann** vergleichbare KI-Systeme an Selbstbedienungskassen.[16]

Bei **EDEKA** ist ein Fall besonders gut dokumentiert: Der selbstständige EDEKA-Kaufmann Beckesepp setzt am Self-Checkout eine KI-gestützte Altersschätzung von Diebold Nixdorf ein, um Artikel mit Altersbeschränkung (etwa Alkohol) automatisiert zu prüfen. Das System schätzt lediglich eine Altersgruppe, ohne

Kategorie	Beispiele	Rechtliche Einschätzung
Weitgehend unbedenklich	Barcode-/Artikelverifikation am SCO, gewichtsbasierte Plausibilitätsprüfung, Exit-Gate-Abgleich, POS-Anomalieerkennung auf Transaktionsdaten	Transaktions- statt personenbezogen; kein Profiling; geringer Eingriff
Grauzone, einzelfallabhängig	Altersverifikation am SCO ohne Identifikation, anlassbezogene Videoanalyse bei konkretem Verdacht	Zulässig unter Voraussetzungen: keine Speicherung, Datenschutz-Folgenabschätzung, menschliche Kontrolle bei Grenzfällen
Praktisch nicht umsetzbar	Flächendeckende Verhaltensanalyse aller Kunden, Gesichtserkennung zur Wiedererkennung (Watchlists), Emotions-/Stresserkennung	Unverhältnismäßig bzw. durch DSGVO Art. 9 und AI Act Art. 5 blockiert

Abb. 5: Was ist zulässig? (Quelle: Eigene Einordnung auf Basis DSK-Orientierungshilfe Videoüberwachung (2020), DSGVO, EU AI Act)

die Person zu identifizieren oder Gesichtsbilder zu speichern, und meldet nur bei unsicherer Einschätzung an das Personal. Laut einer Fallstudie von Intel reduziert dies Mitarbeitenden-Interventionen um 45 % und verkürzt die Bearbeitungszeit pro Artikel von 15 auf 3 Sekunden.[18]

Auch **ALDI Süd** testet in Deutschland eine vergleichbare Obst- und Gemüseerkennung am Self-Checkout (Diebold Nixdorf Smart Vision)[19], während die **Schwarz-Gruppe** (Lidl, Kaufland) über ihre Digitaltochter Schwarz Digits in das deutsche KI-Unternehmen Aleph Alpha investiert hat und laut Presseberichten den KI-Einsatz an ihren rund 1.700 Selbstbedienungskassen prüft.[16]

Verhaltener als international

Eine Studie von DIHK und ibi Research aus dem Jahr 2026 bestätigt: Pilotprojekte zur KI-gestützten Überwachung werden in Deutschland „oft abgebrochen oder gar nicht gestartet" – vor allem wegen der in Kapitel 6 beschriebenen Rechtsunsicherheit bei personenbezogenen Ansätzen. Öffentlich dokumentierte, großflächige Loss-Prevention-Systeme deutscher Anbieter existieren bislang kaum; die genannten Beispiele sind überwiegend transaktionsbezogen und decken sich mit dem in Kapitel 6 skizzierten rechtlich unbedenklichen Korridor.

Auf Ebene der KI-Adoption insgesamt zeigt die HDE-KI-Studie 2025 ein differenziertes Bild: 21,6 % der befragten Handelsunternehmen befinden sich in Pilotprojekten (ein Anstieg von 46 % gegenüber 2023), 16,2 % setzen KI bereits breiter ein, und bei 9,6 % ist die Einführung abgeschlossen.[20] KI ist im deutschen Handel also angekommen – konkrete Anwendungen für Bestandsgenauigkeit im engeren Sinne bleiben davon aber noch die Ausnahme.

7.2 Internationale Referenzen: Wo der Markt weiter ist

International zeigen mehrere Handelsunternehmen bereits belastbare Ergebnisse aus dem großflächigen Einsatz von KI-Vision-Systemen. Der Loss-Prevention-Spezialist Everseen ist nach eigenen Angaben in mehr als 8.600 Filialen im Einsatz, unter anderem bei Walmart, Costco, Kroger, ASDA und Tesco, und verarbeitet nach eigenen Angaben rund 15 Millionen Transaktionen pro Tag.[13] Eine Forrester-Studie (Total Economic Impact, 2024) bescheinigt einer vergleichbaren Everseen-Implementierung einen ROI von 374 %[21] – die Studie bezieht sich auf ein von Forrester modelliertes zusammengesetztes Unternehmen und ist nicht als eine von Walmart selbst veröffentlichte Kennzahl zu verstehen, auch wenn Walmart zu den öffentlich genannten Everseen-Kunden zählt.

Der französische Handelskonzern **Intermarché** konnte mit einer Vision-KI-Lösung von SeeChange am Self-Checkout die Fraud-Rate von rund 3 % auf unter 1 % senken – bei gleichzeitiger Unterscheidung zwischen vorsätzlichem Diebstahl und unbeabsichtigten Bedienfehlern.[14] Der britische Handelskonzern **Morrisons** setzt die Plattform von Focal Systems für automatisiertes Regal-Monitoring ein, das Out-of-Stock-Situationen und Planogramm-Abweichungen in Echtzeit erkennt.[22] In Polen betreibt die Handelskette **Biedronka** KI-gestützte Obst- und Gemüseerkennung sowie No-Scan-Detection an rund 15.000 Selbstbedienungskassen in 87 % ihrer Filialen.[23]

Auch im Bereich Bestandsplanung und Disposition gibt es belastbare Referenzen: Der deutsche Baumarktkonzern **Hornbach** hat 2024 eine Partnerschaft mit Blue Yonder für Order-Management- und Bestandslösungen bekanntgegeben, um Nachschub und Warenverfügbarkeit datengetriebener zu steuern.[24] Die US-Handelskette **Albertsons** nutzt KI-gestützte Bestellvorschläge des Anbieters Afresh für die Frischetheke in mehr als 2.200 Filialen.[25]

7.3 Was diese Beispiele gemeinsam haben

- **Fokus auf den Self-Checkout:** Die meisten produktiven Loss-Prevention-Deployments zielen auf den SCO, nicht auf flächendeckende Verkaufsflächen-Überwachung – dort ist der ROI am klarsten messbar und die rechtliche Lage am eindeutigsten.
- **Transaktions- statt Personenbezug:** Die rechtlich unproblematischsten und zugleich wirtschaftlich erfolgreichsten Beispiele prüfen die Ware bzw. den Scan-Vorgang, nicht die Person.
- **Mensch bleibt im Loop:** Selbst Amazon hat reine „Just Walk Out"-Konzepte ohne jede Kassierinteraktion teilweise zugunsten hybrider „Dash Cart"-Lösungen zurückgefahren – die Branche bewegt sich zu KI-unterstützten statt vollautomatisierten Prozessen.
- **Deutschland mit Aufholpotenzial:** Während internationale Handelsunternehmen KI-Loss-Prevention bereits in tausenden Filialen betreiben, stehen vergleichbare deutsche Initiativen überwiegend noch am Anfang – ein Umstand, der frühen Investoren einen relativen Wettbewerbsvorteil verschaffen kann.

8. Wirtschaftlicher Nutzen und ROI

Die in Kapitel 5 vorgestellten Bausteine sind kein Selbstzweck. Für Entscheiderinnen und Entscheider mit Ergebnisverantwortung zählt am Ende eine Frage: Was bringt das konkret, und in welchem Zeitraum? Dieses Kapitel fasst die belastbarsten verfügbaren Referenzwerte zusammen und zeigt, wie sich daraus ein unternehmensspezifischer Business Case ableiten lässt.

8.1 Referenzwerte aus Industrie und Forschung

Maßnahme	Belegter Effekt	Quelle
Datengetriebene Bestandsgenauigkeit	20–40 % Schwundreduktion	Pygmalios / Altavant Consulting[5]
Verbesserung der Bestandsdatengenauigkeit (IRA)	0,68-1,5 % Umsatzeffekt	Pygmalios / Altavant Consulting[5]
ML-basierte Frische-Disposition	bis zu 80 % weniger Out-of-Stock über 10 % weniger Abschriften bis zu 9 % höhere Bruttomarge	McKinsey[12]
Korrektur ungenauer Bestandsdatensätze	4–8 % Umsatzsteigerung	ECR Community[3]
Risikobasierte Zählpriorisierung	Reduktion der Zählungen ohne Mehrwert (heute 80–90 %)	codecentric-Whitepaper „Real-time Retail“[10]

Abb. 6 (Quelle: EHI Retail Institute / handelsdaten.de, Studie „Inventurdifferenzen 2026“; eigene Auswertung)

Diese Werte stammen aus unterschiedlichen Studien und Branchenkontexten und sollten nicht unreflektiert addiert werden – sie zeigen aber übereinstimmend, dass der Hebel bei Bestandsgenauigkeit real und in mehreren unabhängigen Untersuchungen dokumentiert ist.

8.2 Eine Beispielrechnung

Um die Größenordnung greifbar zu machen, hilft ein vereinfachtes Rechenbeispiel wie in Abb. 7 für ein größeres Handelsunternehmen mit 1 Milliarde Euro Jahresumsatz und einer Schwundquote nahe dem Branchendurchschnitt von 0,64 % (Einkaufspreisbasis).

Wichtig ist der Hinweis, dass die beiden Effekte – Schwundreduktion und Verbesserung der Inventory Record Accuracy (IRA) – nicht deckungsgleich sind: Der erste bezieht sich direkt auf die jährliche Inventurdifferenz, der zweite auf die laufende Genauigkeit der Bestandsdatensätze, die sich unter anderem in Umsatzsteigerungen durch bessere Verfügbarkeit niederschlägt. Beide Hebel wirken parallel, sollten aber getrennt betrachtet und im eigenen Controlling nicht doppelt verrechnet werden.

8.3 Warum sich der Business Case schnell rechnet

- **Kurze Time-to-Value:** Anders als große Transformationsprogramme lässt sich ein Pilotprojekt zur Bestandsgenauigkeit auf Basis bereits vorhandener Kassendaten und Bestandssysteme innerhalb weniger Wochen aufsetzen.

Größe	Wert
Jahresumsatz	1 Mrd. €
Inventurdifferenz bei 0,64 % Schwundquote	~6.400.000 €
Angenommene Schwundreduktion (konservatives Szenario, 20 %)	~1.280.000 € p. a.
Angenommene Schwundreduktion (oberes Szenario, 40 %)	~2.560.000 € p. a.
Zusätzlicher Effekt aus 1 %-Punkt IRA-Verbesserung	6.850.000–15.000.000 US-Dollar (separater Hebel, siehe oben, hochgerechnet auf 1 Mrd. Umsatz)

Abb. 7: Rechenbeispiel (Quelle: EHI Retail Institute / handelsdaten.de, Studie „Inventurdifferenzen 2026“; eigene Auswertung)

- **Direkte Messbarkeit:** Die Inventurdifferenz ist eine harte, jedem Finanzvorstand vertraute Kennzahl. Eine Verbesserung lässt sich unmittelbar in Euro ausweisen, ohne komplexe Attributionsmodelle.
- **Kein Vorabinvestment in neue Hardware nötig:** Die in Kapitel 5.1 bis 5.4 beschriebenen Bausteine setzen primär auf vorhandenen Datenquellen auf. Nur der in Kapitel 5.5 beschriebene Vision-Baustein am Self-Checkout erfordert zusätzliche Kamera- oder Sensorhardware.
- **Skalierbarkeit über die erste Filiale hinaus:** Ist die Datenbasis einmal aufgebaut, lassen sich weitere Filialen mit vergleichsweise geringem Zusatzaufwand anschließen – die größten Kosten entstehen bei der Ersteinrichtung, nicht beim Rollout.

Entscheidungshilfe kompakt

Schon eine Verbesserung der Bestandsgenauigkeit um wenige Zehntelprozentpunkte kann bei größeren Handelsunternehmen Einsparungen in sechs- bis siebenstelliger Höhe pro Jahr bedeuten. Bei Investitionskosten, die deutlich unterhalb einer klassischen IT-Transformation liegen, ergibt sich in aller Regel eine Amortisation innerhalb weniger Monate bis maximal eines Jahres.

9. Vom Piloten zur Skalierung: Ein pragmatischer Einstieg

Der Umstieg auf KI-gestützte Bestandsgenauigkeit erfordert keine umfassende IT-Transformation. Empfehlenswert ist ein schrittweises Vorgehen, das schnell Ergebnisse liefert und auf jeder Stufe einen eigenständigen ROI ausweist.

9.1 Ein vierstufiger Einstiegspfad

Stufe 1: Datenbestandsaufnahme und Mismatch Risk Score

Zusammenführung der vorhandenen POS-, ERP-, Warenwirtschafts- und Lagerdaten für einen begrenzten Filial- und Sortimentsausschnitt. Aufbau eines ersten Mismatch Risk Scores, der zeigt, wo die größten Bestandsrisiken liegen – ohne dass bereits operative Prozesse verändert werden müssen.

Stufe 2: Pilotprojekt risikobasiertes Cycle Counting

Umstellung der Zählpraxis für die Pilotfilialen auf Basis des Risikoscores. Diese Stufe liefert den ersten harten Beleg für den Business Case, weil sich Zählaufwand und Trefferquote unmittelbar vor und nach der Umstellung vergleichen lassen.

Stufe 3: Anbindung von Disposition und Forecasting

Sobald die Bestandsdaten in den Pilotfilialen nachweislich zuverlässiger sind, lassen sich Nachfrageprognose und automatisierte Nachbestellung darauf aufsetzen. Diese Stufe adressiert direkt die Out-of-Stock-Problematik aus Kapitel 3.

Stufe 4: Skalierung und weitere Bausteine

Rollout auf weitere Filialen sowie schrittweise Ergänzung um Dynamic Pricing für verderbliche Sortimente und – sofern rechtlich und organisatorisch gewünscht – KI-Vision am Self-Checkout gemäß dem in Kapitel 6 beschriebenen rechtlichen Korridor.

Stufe	Ergebnis
1. Datenbestandsaufnahme & Mismatch Risk Score	Transparenz über Risikoartikel und -filialen
2. Risikobasiertes Cycle Counting (Pilot)	Reduzierter Zählaufwand, erster messbarer ROI
3. Disposition & Forecasting	Weniger Out-of-Stock, weniger Phantom-Bestand
4. Skalierung & weitere Bausteine	Rollout, Dynamic Pricing, ggf. Vision am SCO

9.2 Erfolgsfaktoren aus der Praxis

- **Klein anfangen, schnell messen:** Ein Pilot in zwei bis drei Filialen mit klar definierten KPIs überzeugt intern schneller als ein großes Rollout-Versprechen ohne Zwischenergebnisse.
- **Fachlichkeit vor Technologie:** Ein Bestandsabfall bei einem Artikel in mehreren Filialen gleichzeitig kann auf organisierten Diebstahl, aber auch auf einen saisonalen Nachfragepeak hindeuten. Diese Einordnung erfordert Retail-Fachwissen, nicht nur ein Machine-Learning-Modell.
- **Erklärbarkeit einfordern:** Risikoscores und Anomalie-Alarme müssen für Filialpersonal und Disposition nachvollziehbar bleiben – „Black-Box"-Ergebnisse untergraben die Akzeptanz und damit den Projekterfolg.
- **Rechtliche Prüfung von Anfang an mitdenken:** Insbesondere bei Vision-Bausteinen am Self-Checkout sollte die Datenschutz-Folgenabschätzung parallel zur technischen Konzeption erfolgen, nicht erst kurz vor dem Rollout.

Fazit

5,11 Milliarden Euro Inventurdifferenz, Tendenz steigend. 98 % unentdeckte Diebstähle trotz 3,1 Milliarden Euro Präventionsaufwand. Bis zu 60 % ungenaue Bestandsdatensätze auf SKU-Ebene. Diese drei Zahlen aus den vorangegangenen Kapiteln beschreiben denselben Kern: Der deutsche Einzelhandel bekämpft überwiegend die Symptome eines Problems, dessen eigentliche Ursache – der ungenaue Systembestand – weitgehend unangetastet bleibt.

Diebstahl bleibt mit rund 85 % der Wertdifferenz die größte Einzelursache, und die rechtlich zulässigen Mittel dagegen sind in Kapitel 6 klar umrissen worden. Doch die verbleibenden 15 % – organisatorische Mängel im Wert von rund 780 Millionen Euro jährlich – sind genau der Hebel, den datengetriebene, KI-gestützte Ansätze am direktesten adressieren können, ohne an rechtliche oder gesellschaftliche Grenzen zu stoßen. Und weil beide Ursachengruppen auf demselben Grundproblem beruhen – einem Systembestand, der der Realität permanent hinterherhinkt –, wirkt eine verbesserte Bestandsgenauigkeit weit über die reine Inventurdifferenz hinaus: auf Disposition, Nachfrageprognose, Preissteuerung und Omnichannel-Angebote gleichermaßen.

Die internationalen Beispiele aus Kapitel 7 zeigen, dass diese Ansätze keine ferne Zukunftsvision sind, sondern in tausenden Filialen produktiv im Einsatz sind – mit belegten Ergebnissen von Schwundreduktionen um 20 bis 40 % bis hin zu einer Fraud-Rate-Halbierung bei Intermarché. Deutschland steht hier noch am Anfang, was aus Sicht früher Investoren ein Vorteil sein kann: Der Wettbewerbsdruck ist noch überschaubar, die Referenzwerte für den Business Case liegen bereits vor.

Key Take-away

Wer Inventurdifferenzen nachhaltig reduzieren will, muss nicht nur Diebe stoppen, sondern vor allem wissen, was tatsächlich im Bestand ist – und genau dafür liefert KI heute die technologische Grundlage. Der Einstieg ist pragmatisch möglich, mit vorhandenen Daten, einem klar abgesteckten rechtlichen Rahmen und einem Business Case, der sich in aller Regel innerhalb weniger Monate rechnet.

Der nächste Schritt liegt nicht in einer weiteren Grundsatzentscheidung, sondern in einem konkreten, eng begrenzten Pilotprojekt wie in Kapitel 9 skizziert. Die Datenbasis dafür ist in den meisten Handelsunternehmen bereits vorhanden.

Über uns | Kontakt

codecentric AG

Wir unterstützen Handelsunternehmen bei der Integration komplexer Systemlandschaften – herstellerunabhängig und technologieagnostisch. Unser interdisziplinäres Team bringt Fachwissen in den Bereichen Data Science, Softwareentwicklung, Cloud-Architekturen und Business-Strategie zusammen.

Unsere Leistungen für den Retail:

- Systemintegration und -modernisierung
- Strategieberatung zur datengetriebenen Kundenbindung
- KI-basierte Bestandsintelligenz
- Entwicklung individueller Machine-Learning-Modelle
- Integration in CRM-, Kampagnen- und Loyalty-Systeme
- Training & Enablement von internen Teams
- u. v. m.

Weitere Leistungen für Retail-Unternehmen findest du auf **https://www.codecentric.de/branchen/handel.**

Kontaktiere uns für ein unverbindliches Erstgespräch und erzähle uns von deinen Herausforderungen. Wir helfen dir, die Muster hinter deinen Inventurdifferenzen sichtbar zu machen, informierte Ableitungen zu treffen und deine Schwundquote nachweislich zu senken.

Markus Lüger
Principal Retail Strategist
handel@codecentric.de

Melanie Volk
VP Consulting
handel@codecentric.de

Quellenverzeichnis

1. EHI Retail Institute / handelsdaten.de: Studie „Inventurdifferenzen 2025/2026“ (sowie Vorjahresstudie „Inventurdifferenzen 2025“ für den 2024er-Vergleichswert). Datenbasis: rund 98 Unternehmen. Kennzahlen: Inventurdifferenz gesamt (5,11 Mrd. € 2025 / 4,95 Mrd. € 2024), Schwundquote (0,64 % EK-Basis), Verursacherstruktur (Kundendiebstahl ~59,5 %, Mitarbeitendendiebstahl ~18 %, Lieferanten/Servicekräfte ~7 %, organisatorische Mängel ~15 %), Präventionsbudget (1,7 Mrd. €) und Gesamtkosten inkl. interner Aufwände (3,1 Mrd. €), unentdeckte Diebstähle (98 %).

2. DeHoratius, N. & Raman, A.: „Inventory Record Inaccuracy: An Empirical Analysis“. Harvard Business School, 2008 — 35–65 % der Bestandsdatensätze auf SKU-Ebene weichen von der Realität ab (LEH-/FMCG-Handel).

3. ECR Europe / ECR Retail Loss Group: „Inventory Inaccuracy in Retailing“ bzw. „Optimal Shelf Availability“ — rund 60 % ungenaue SKU-Records im Lebensmittel- und FMCG-Handel; Out-of-Stock-Rate im europäischen LEH von 7–8 %, davon rund 50 % datengetrieben; Korrektur ungenauer Bestandsdatensätze führt zu 4–8 % Umsatzsteigerung.

4. EHI Retail Institute: Studie „Technologie-Trends im Handel 2025“ — 100 % der befragten Retail-CIOs in Deutschland bewerten künstliche Intelligenz als wichtigsten Zukunftstrend.

5. Pygmalios / Altavant Consulting: ROI-Referenzwerte für datengetriebene Bestandsgenauigkeit — 20–40 % Schwundreduktion; eine Verbesserung der Inventory Record Accuracy (IRA) um 1 %punkt entspricht 685.000 bis 1,5 Millionen US-Dollar bei 100 Millionen US-Dollar Umsatz.

6. EHI Retail Institute: Studie „Inventurdifferenzen 2024“ (Leseprobe) — LEH-spezifische Warengruppenquoten: Food-Sortiment 0,79 %, Nonfood-Sortiment 0,45 % (Bezugsjahr 2023, EK-/Nettoumsatzbasis).

7. EHI Self-Checkout-Initiative: Markterhebung 2025 — rund 38.650 Selbstbedienungskassen im deutschen Einzelhandel (davon ca. 25.000 im LEH), Anstieg der SCO-Standorte um 143 % innerhalb von zwei Jahren, Schwundrate SCO 3,5 % vs. 0,2 % an bemannten Kassen (17-facher Wert).

8. IHL Group: „Retail Inventory Crisis Persists“, 2025 — globale Kosten von Bestandsverzerrungen (Out-of-Stock- und Überbestandskosten) von 1,73 Billionen US-Dollar; Unternehmen mit aktivem KI-/ML-Einsatz in der Bestandssteuerung verzeichnen 2,3-fach höheres Umsatzwachstum und 2,5-fach höheres Gewinnwachstum als Wettbewerber mit traditionellen Methoden („AI Haves“ vs. „AI Have-nots“).

9. Zebra Technologies: Herstellerdaten zu Phantom Inventory — rund 8 % aller Bestandsverluste entfallen auf Phantom-Bestand (Systembestand ohne physische Deckung).

10. codecentric AG: Whitepaper „Real-time Retail: Echtzeitfähigkeit als Erfolgsfaktor im Handel“ — isolierte Systeminseln zwischen POS, ERP, Warenwirtschaft und Lagerverwaltung; rund 80–90 % aller Inventurzählungen liefern keinen belastbaren Mehrwert.

11. DIHK (Deutscher Industrie- und Handelskammertag) / ibi Research an der Universität Regensburg: Studie zu KI-gestützter Videoüberwachung im Einzelhandel (2026) — Pilotprojekte werden in Deutschland „oft abgebrochen oder gar nicht gestartet“, während in anderen EU-Ländern mit weniger restriktiver DSGVO-Auslegung bereits Praxistests laufen (berichtet u. a. über dihk.de und heise.de).

12. McKinsey & Company: „The Secret to Smarter Fresh-Food Replenishment“ — ML-basierte Frische-Disposition im Lebensmitteleinzelhandel: bis zu 80 % weniger Out-of-Stock-Situationen, über 10 % weniger Abschriften, bis zu 9 % höhere Bruttomarge.

13. Everseen: Unternehmensangaben — Einsatz in mehr als 8.600 Filialen, u. a. bei Walmart, Costco, Kroger, ASDA und Tesco; Verarbeitung von rund 15 Millionen Transaktionen pro Tag (everseen.com).

14. SeeChange (Diebold Nixdorf): Vendor- und Presseangaben zur Vision-KI-Lösung bei Intermarché — Reduktion der Fraud-Rate am Self-Checkout von rund 3 % auf unter 1 %, mit Unterscheidung zwischen vorsätzlichem Diebstahl und unbeabsichtigten Bedienfehlern (seechange.com).

15. Datenschutzkonferenz (DSK): „Orientierungshilfe der Aufsichtsbehörden zur Videoüberwachung durch nicht-öffentliche Stellen“ (2020) — Verhältnismäßigkeitskriterien für Videoüberwachung im Einzelhandel, Speicherfristen (Richtwert 48–72 Stunden).

16. dpa-Umfrage unter deutschen Einzelhändlern, berichtet u. a. über tagesschau.de, zdfheute.de und chip.de — REWE, Rossmann

und die Schwarz-Gruppe (Lidl, Kaufland) setzen KI-Systeme an Selbstbedienungskassen ein oder testen diese.

17. Presseberichte zu IKEA Deutschland (u. a. zdfheute.de, tagesschau.de) — KI-gestützte Fehlscan-Erkennung an Selbstbedienungskassen, Rollout auf alle 54 deutschen Filialen.

18. Intel Case Study: EDEKA Beckesepp / Diebold Nixdorf „Vynamic Smart Vision | Age Verification" — KI-gestützte Altersschätzung am Self-Checkout ohne Gesichtsidentifikation oder -speicherung; Reduktion von Mitarbeiter-Interventionen um 45 %, Verkürzung der Bearbeitungszeit pro Artikel von 15 auf 3 Sekunden.

19. Presseberichte zu ALDI Süd (u. a. supermarktblog.com) — Test von Obst- und Gemüseerkennung am Self-Checkout auf Basis von Diebold Nixdorf Smart Vision.

20. HDE (Handelsverband Deutschland): „HDE-KI-Studie 2025" — 21,6 % der befragten Handelsunternehmen befinden sich in KI-Pilotprojekten (+46 % gegenüber 2023), 16,2 % setzen KI bereits breiter ein, bei 9,6 % ist die Einführung abgeschlossen.

21. Forrester Consulting: „The Total Economic Impact™"-Studie, 2024 — modelliert für ein zusammengesetztes Unternehmen mit einer Everseen-Implementierung einen ROI von 374 %; keine von Walmart selbst veröffentlichte Kennzahl.

22. Focal Systems: Presse- und Vendor-Angaben zum Einsatz bei Morrisons (UK) — automatisiertes Regal-Monitoring zur Echtzeit-Erkennung von Out-of-Stock-Situationen und Planogramm-Abweichungen (itransition.com).

23. Presseberichte zu Biedronka (Polen), u. a. supermarktblog.com — KI-gestützte Obst- und Gemüseerkennung sowie No-Scan-Detection an rund 15.000 Selbstbedienungskassen in 87 % der Filialen.

24. Hornbach Baumarkt AG / Blue Yonder: Pressemitteilung 2024 — Partnerschaft für Order-Management- und Bestandslösungen zur datengetriebenen Steuerung von Nachschub und Warenverfügbarkeit.

25. Albertsons Companies / Afresh: Presse- und Vendor-Angaben — KI-gestützte Bestellvorschläge für die Frischetheke in mehr als 2.200 Filialen.

Bestandsgenauigkeit ist kein Zufall. Mit KI gegen das leere Regal

codecentric

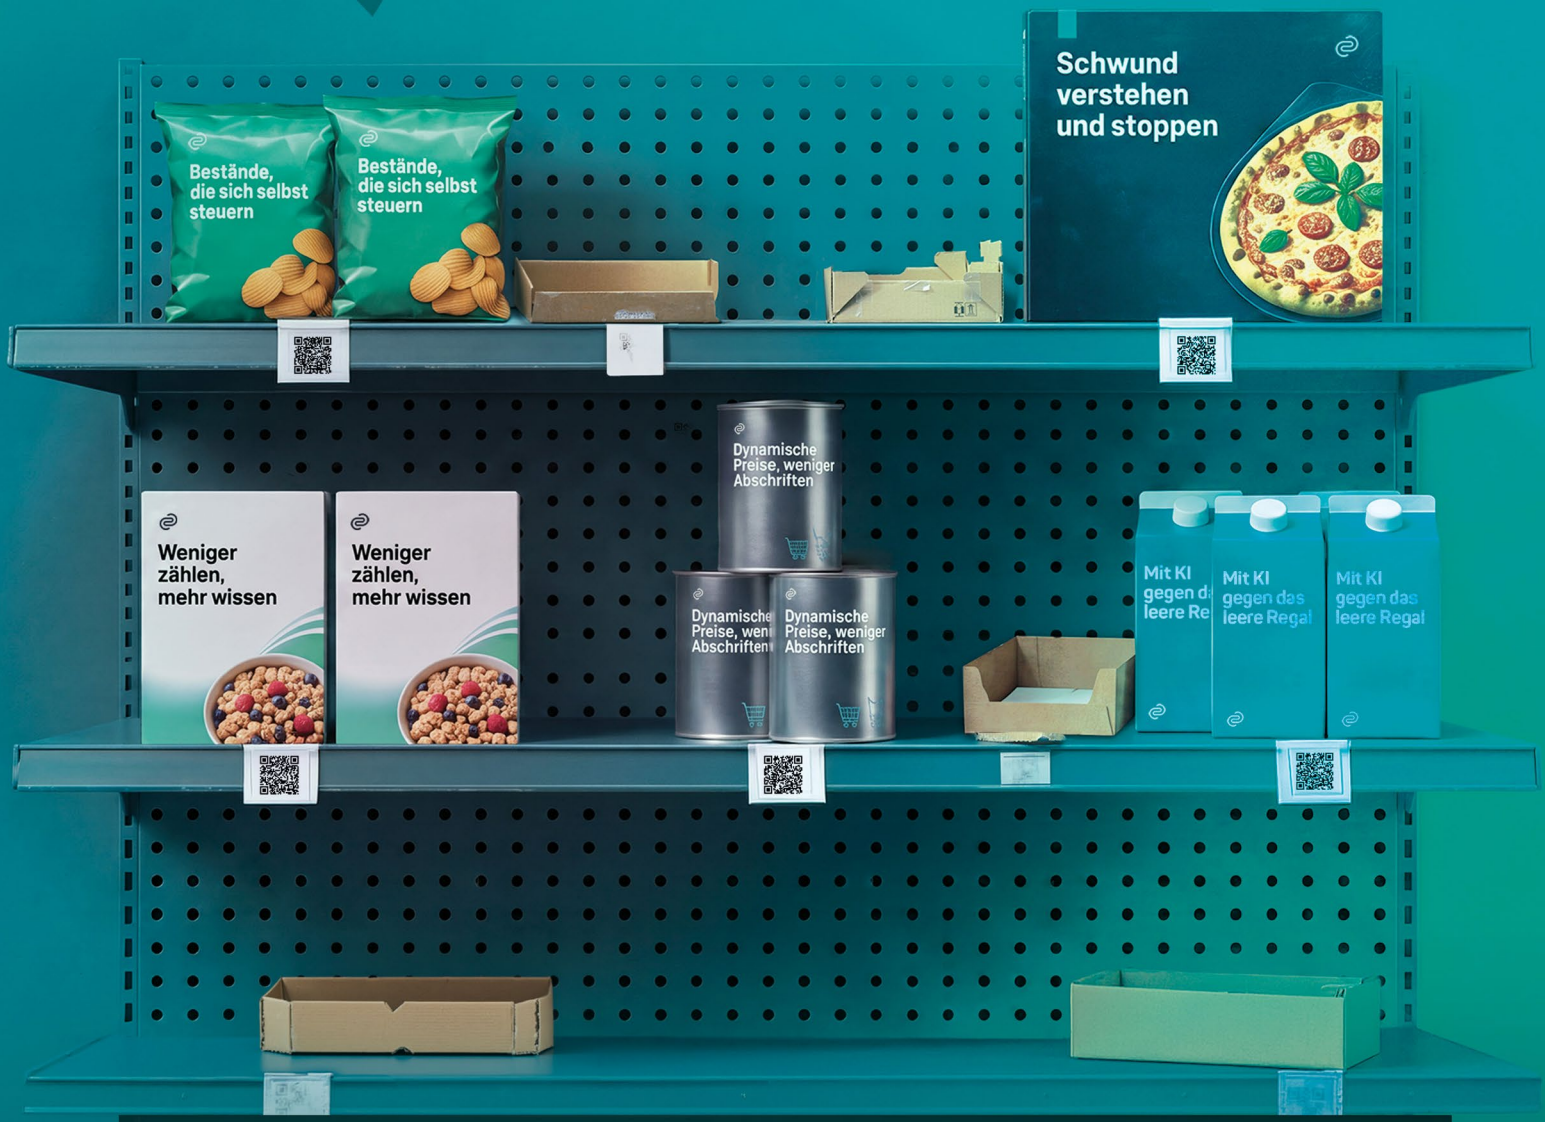

http://www.codecentric.de/branchen/handel

http://www.codecentric.de/branchen/handel