Nachhaltiges Retourenmanagement im E-Commerce

Entwicklung eines Klassifikationsmodells zur Identifizierung von nicht mehr verwendbaren Retouren

Anthony Boyd Stevenson [1], Katherina Meißner [2] und Julia Rieck [3]

Abstract: In einer Zeit, in der der E-Commerce stetig wächst, stehen Unternehmen vor der Herausforderung das Retourenmanagement sowohl ökonomisch als auch ökologisch zu gestalten und zu optimieren. Diese Case Study präsentiert ein Klassifikationsmodell zur Identifizierung von nicht mehr verwendbaren Retouren, das in Zusammenarbeit mit einem deutschen Onlinehändler für Möbel und Wohnaccessoires erarbeitet wurde. Mittels eines Datensatzes von etwa 300.000 Retouren kann das Klassifikationsmodell die Wahrscheinlichkeit ermitteln, ob ein retournierter Artikel wieder angeboten werden kann oder ob er entsorgt werden muss. In letzterem Fall kann eine Entsorgung durch den Kunden dafür sorgen, dass die Anzahl der Rücktransporte, die Transportkosten und die umweltschädlichen Emissionen reduziert werden. Methodisch stützt sich die Modellentwicklung auf die Open-Source-Software KNIME und das Verfahren Gradient Boosted Trees. Die Modellvalidierung erfolgt durch anerkannte Evaluationsmetriken. Die Ergebnisse zeigen das große Potenzial einer Kostensenkung und einer möglichen Verbesserung der ökologischen Bilanz im Retourenmanagement auf.

Keywords: Nachhaltigkeit, E-Commerce, Retourenmanagement, Case Study, Klassifikationsmodell

1 Einleitung

Retouren im E-Commerce haben für Onlinehändler erhebliche wirtschaftliche Auswirkungen und sie bringen logistischen Aufwand, hohe Kosten sowie umweltschädliche Emissionen mit sich. Deshalb ist es notwendig, die Retourenprozesse in den Fokus zu nehmen und zu optimieren, wobei sowohl präventive Maßnahmen (z. B. die freiwillige Zahlung einer Gutschrift für Bestellungen ohne Rücksendung) als auch kurative Ansätze (z. B. die Wiederaufbereitung des Produkts zur voll funktionsfähigen Gebrauchtware) verfolgt werden können [As14]. Die vorliegende Case Study zeigt, dass ein nachhaltiges und innovatives Retourenmanagement sich positiv auf das Wertschöpfungssystem und die jeweiligen Akteure auswirkt. In Kooperation mit einem deutschen Onlinehändler für

[1] Universität Hildesheim, Institut für Betriebswirtschaft und Wirtschaftsinformatik, Universitätsplatz 1, 31141 Hildesheim, stevenson@uni-hildesheim.de, https://orcid.org/0000-0002-1402-8560
[2] Universität Hildesheim, Institut für Betriebswirtschaft und Wirtschaftsinformatik, Universitätsplatz 1, 31141 Hildesheim, meissner@uni-hildesheim.de, https://orcid.org/0000-0002-1538-4129
[3] Universität Hildesheim, Institut für Betriebswirtschaft und Wirtschaftsinformatik, Universitätsplatz 1, 31141 Hildesheim, rieck@bwl.uni-hildesheim.de, https://orcid.org/0000-0002-6569-0239

doi:10.18420/inf2024_158

Möbel und Wohnaccessoires betrachten wir die Bearbeitung von Retourenanfragen und die Abstimmungsprozesse zwischen Kundendienst und Logistik. In diesem Kontext sollen insbesondere nicht mehr verwendbare Retouren ermittelt werden, um für diese frühzeitig eine ökonomische und ökologische Lösung zu realisieren.

Retouren, die sich nicht mehr für den Wiederverkauf als A-Ware oder auch als rabattierte Ware eignen, werden als „*Nicht verwendbar*“ einsortiert und typischerweise einer Entsorgung zugeführt. Sie verursachen einen großen wirtschaftlichen Verlust für einen Onlinehändler. Zur Identifikation von nicht verwendbaren Retouren entwickeln wir ein Klassifikationsmodell, das zum Ziel hat, für retournierte Artikel die Wahrscheinlichkeit der Entsorgung vorherzusagen. Somit können Rücksendungen effizienter und nachhaltiger gesteuert werden. Unser Ansatz konzentriert sich auf die Extraktion von Handlungsanweisungen aus erkennbaren Datenmustern, was eine datengetriebene Prozessoptimierung ermöglicht. Kernstück der Modellierung ist ein Gradient-Boosted-Tree-Modell, dessen Prognosequalität durch bekannte Evaluationsmetriken bestätigt wird. Die gesamte Umsetzung erfolgt mit der Open-Source- und Low-Code-Software KNIME, wodurch eine leichte Implementierung beim Kooperationspartner auch ohne tiefgreifende Programmierkenntnisse möglich wird. Die Ergebnisse der Studie demonstrieren, dass das Klassifikationsmodell nicht verwendbare Retouren effizient auffinden kann. In Kombination mit der Möglichkeit, dass Kunden die Retouren selbst entsorgen, (d. h., die Produkte werden nicht zurückgeschickt sondern vor Ort beim Kunden entsorgt, durch den Kunden einem Wiederverwerter übergeben oder doch beim Kunden verwendet), können Retourenkosten verringert und auch eine Reduzierung von CO_2-Emissionen vorangetrieben werden.

Im weiteren Verlauf betrachten wir im Kapitel 2 relevante Arbeiten, um die Verortung der vorliegenden Arbeit im theoretischen Bezugsrahmen zu verdeutlichen und diese gleichzeitig von anderen Forschungsarbeiten abzugrenzen. Anschließend wird in Kapitel 3 die Ausgangslage unserer Case Study mit den zentralen Herausforderungen von Retouren für das Transportwesen diskutiert und die Bedeutung der Prozessoptimierung für die Förderung der Nachhaltigkeit erörtert. In Kapitel 4 wird der Fokus auf die Umsetzung der Case Study gelegt. Dabei beginnen wir mit einer Vorstellung des zugrundeliegenden Datensatzes und gehen dann auf die Entwicklung des Klassifikationsmodells und dessen Evaluation ein. Danach thematisieren wir in Kapitel 5 die ökonomischen und ökologischen Auswirkungen der Erkenntnisse. Abschließend bieten wir in Kapitel 6 ein Fazit und einen Ausblick auf weiterführende Fragestellungen und zukünftige Forschungsmöglichkeiten.

2 Verwandte Arbeiten

Für die Betrachtung von relevanter Literatur ist es von Bedeutung, die Branchenumgebung unseres in Deutschland ansässigen Kooperationspartners, der als Onlinehändler für Möbel

und Wohnaccessoires tätig ist, zu differenzieren. Dies ist notwendig, da die Branchenumgebung maßgeblich die Ausgangsbedingungen bezüglich Retouren beeinflusst und daher bei der Entwicklung des Klassifikationsmodells berücksichtigt werden muss. So erfordern Rücksendungen von Möbeln und Wohnaccessoires bspw. im Vergleich zu Kleidungsstücken wie Pullovern unterschiedliche Prozesse mit andersartigen Herausforderungen, z. B. aufgrund von unterschiedlichen Größenvariationen der Waren, der teils aufwendigeren Verpackung sowie dem oft erforderlichen zusätzlichen Schutz der Produkte. Als konkrete Beispiele seien hier die Rücksendung sperriger Möbel wie Sofas im Vergleich zu einzelnen Kleidungsstücken wie T-Shirts genannt, oder die Abwicklung von Retouren für zerbrechliche Dekorationsgegenstände wie Spiegel im Gegensatz zu robusten Stoffwaren wie Jeans.

Die Berücksichtigung der branchenspezifischen Merkmale ist entscheidend für die Entwicklung eines präzisen Klassifikationsmodells zur Vorhersage der Verwertbarkeit von Retouren, da sowohl die unterschiedlichen Produktmerkmale als auch die logistischen Prozesse die Effektivität des Modells beeinflussen können. Ein weiterer entscheidender Faktor ist die differenziertere und seltener vorkommende Bestellung von Möbeln und Wohnaccessoires im Onlinehandel im Vergleich zum Modebereich, was sich sowohl im Branchenumsatz als auch in den Retourenraten niederschlägt [AK22]. Kunden neigen in der Regel dazu, bei Möbeln und Wohnaccessoires weniger impulsiv zu kaufen. Im Gegensatz dazu bestellen Kunden im Modebereich gelegentlich bewusst mehr Produkte zur Auswahl, oft mit der Absicht, nicht erwünschte Größen- oder Farbvarianten zu retournieren. Das gleiche Bestellverhalten bei Möbeln wie Sofas ist aufgrund der Produktgröße und des Transports logistisch aufwendiger und für Kunden weniger praktikabel. Abschließend sei hinzugefügt, dass im Rahmen der vorliegenden Arbeit Echtdaten und keine simulierten Daten verwendet wurden.

Im Rahmen einer systematische Literaturrecherche wurden in Ka24 Studien zur Prognose von Retouren im E-Commerce zusammengetragen und beleuchtet. Die von Ka24 untersuchten 25 Studien wurden hinsichtlich von drei Kategorien untersucht: Geschäftsart, Datentyp und Branche. Die untersuchten Geschäftsarten waren stationärer Handel, Direktvermarkter und E-Commerce. Die aufgeführten Branchen waren Mode, Consumer Electronics, Kosmetika, Baumaterial oder Wohnaccessoires. Zusätzlich wurden die Studien dahingehend unterteilt, was für die Retouren vorhergesagt werden sollte, z. B. die Menge oder das Volumen sowie die Gründe der Retourenentscheidung. Die Branche Wohnaccessoires, zu der auch die vorliegende Arbeit zählt, umfasst zwei Studien: DL16 und Ke20. DL16 nutzen Zeitreihen von Bestellungen und Retouren, um bspw. mit der exponentiellen Glättung oder dem Holt-Winters-Ansatz die Retourenmenge zu prognostizieren. Dabei liegt ein besonderer Fokus auf der Identifikation von potenziell missbräuchlich zurückgeschickten Waren. Der durch die unrechtmäßige Einleitung einer Retoure von bspw. benutzter Ware entstandene Schaden und eine möglicherweise erhöhte Bearbeitungsdauer im Retourenprozess sollen erkannt und vorhergesagt werden. Dadurch kann die Effizienz im Retourenmanagement optimiert werden. Trotz der vergleichbaren Motivation der Studie weicht der von uns entwickelte Ansatz dahingehend ab, dass wir die Retourenverwertung maximieren und gleichzeitig die negativen ökologischen und

ökonomischen Auswirkungen von Rücksendungen minimieren. Ke20 analysiert das Rückgabeverhalten von Kunden, das durch großzügige Rückgabepolitiken von Einzelhandelsunternehmen ausgelöst wird und hohe Kosten verursacht. Auf Basis von empirischen Erkenntnissen werden Vorhersagemodelle vorgestellt, die ein aktives Eingreifen seitens der Unternehmen ermöglichen und hierdurch die Möglichkeit bieten, Kosten einzusparen, die andernfalls durch vermeidbare, missbräuchliche Retouren anfallen würden. Das in unserem Ansatz enthaltene Angebot an den Kunden, defekte Ware selbst zu entsorgen, bietet Potenzial für den Missbrauch der Regelung. Die Erkenntnisse der Studie von Ke20 können beim Einsatz unseres Klassifikationsmodells unterstützen, dieses frühzeitig zu erkennen. Aus der Literaturrecherche von Ka24 lässt sich ableiten, dass insbesondere die Prognose von zu entsorgenden Retouren im E-Commerce in der Branche Möbel und Wohnaccessoires nicht im Detail bearbeitet wurde. Die Ableitung von CO_2-Einsparungen auf Basis von Echtdaten hebt unseren Ansatz darüber hinaus ebenfalls hervor.

Die Studie von De16 untersucht, welche strategischen Entscheidungen Onlinehändler der Modebranche treffen sollten, um Retouren zu reduzieren, Umsatzsteigerungen durch ein verbessertes Retourenmanagement zu erreichen sowie eine ausreichende Effizienz im Retourenmanagement zu erlangen. Die Studie beschränkt sich allerdings auf qualitative Daten aus Interviews und untersucht ausschließlich Unternehmen in den Niederlanden. Während die Studie den thematischen Kontext der vorliegenden Arbeit umfasst, wird im Rahmen unserer Arbeit quantitativ geforscht, indem ein Klassifikationsmodell entwickelt und anhand von anerkannten Evaluationsmetriken getestet wird.

In der Studie von FL21 wird ein generisches Modell für die Echtzeit-Vorhersage von Rücksendungen entwickelt, das auf Kundeninteraktionen und Warenkorb-Analysen basiert. Das Ziel besteht darin, potenzielle Rücksendungen zu verhindern, indem das Modell bereits bei der Erstellung des Warenkorbs die Retourenwahrscheinlichkeit evaluiert. Durch die Integration von Machine-Learning-Modellen und Daten aus bisherigen Bestellungen und Retouren ermöglicht das Modell dem Unternehmen, potenzielle Rückgaben vorab zu identifizieren, noch bevor die Bestellung im ERP-System erfasst wird. Es handelt sich, wie bei unserem Ansatz, um ein datengetriebenes Vorgehen zur Reduzierung von Retouren im E-Commerce. Jedoch setzt FL21 an einer anderen Stelle des Retourenprozesses an, nämlich bereits bei der Bestellung. Der Beitrag kann daher im Bereich des präventiven Retourenmanagements angesiedelt werden. Unsere Arbeit setzt erst nach der Retourenentscheidung durch den Kunden an und verhindert vor allem den unnötigen Transport nicht mehr verwendbarer Ware.

Die Studie von Wa14 nutzt eine Literaturrecherche und qualitative Interviews, um die Beweggründe und Konsequenzen der Implementierung eines Product Returns Management Systems durch Onlinehändler zu verstehen sowie um Maßnahmen zur Reduzierung von Produktretouren zu identifizieren. Insgesamt hebt die Forschung hervor, dass die bestehende Literatur hauptsächlich die Verwendung von monetären Instrumenten zur Rückgabenvermeidung betont, die qualitativen Interviews zeigen jedoch, dass prozedurale und kundenzentrierte Instrumente von Onlinehändlern bevorzugt werden.

Auch unsere Arbeit nutzt prozedurale und kundenzentrierte Instrumente, um die Verwertung von Retouren zu maximieren. Insbesondere wird die Entscheidung über die Entsorgung beim Kunden bei der Erstellung des Retourenscheins getroffen (prozedural). Zudem müssen unnötige Retouren nicht mehr zurückgeschickt werden (kundenzentriert). Darüber hinaus zeigt unsere Arbeit eine konkrete und evaluierte Anwendung.

AKS21 verdeutlicht die Relevanz eines effizienten Retourenmanagements im E-Commerce aufgrund zunehmender Onlinekäufe und Retourenquoten. Die Untersuchung unter 143 Onlinehändlern beleuchtet entscheidende Kennzahlen wie Retourenquoten, Bearbeitungszeiten, Kosten und insbesondere Verwertungsoptionen, einschließlich der umweltgerechten Entsorgung. Um Retouren zu reduzieren, lassen sich Maßnahmen mit und ohne Kompensation unterscheiden. AS18 zeigen auf, dass Händler (wie bspw. Amazon) Kunden von einem Rücktransport abraten, wenn die Retourenbearbeitung teurer als der Warenwert ist. Die Kunden können als Kompensation für entstandene Unannehmlichkeiten die Produkte behalten. Reaktionen auf günstigere Konkurrenzangebote beinhalten oft eine Preisunterschiedserstattung durch den Händler. Zu den Maßnahmen ohne Kompensation gehören komplizierte Rücksendeprozesse oder die Betonung der ökologischen Auswirkungen von Retouren. Häufig wird mit Abschreckung gearbeitet, was aber möglicherweise die Kundenzufriedenheit beeinträchtigt.

Aufbauend auf den Erkenntnissen aus AS18 nutzen wir in der Case Study die Möglichkeit der Kompensation, indem wir bei nicht mehr verwendbaren Retouren die Entsorgung dem Kunden überlassen. Durch diese Maßnahme werden die Retourenbearbeitungskosten des Kooperationspartners sowie die ökologischen Auswirkungen des Transports deutlich reduziert. Zur Identifikation von nicht verwendbaren Retouren sind allerdings zuverlässige Verfahren erforderlich. Es muss insbesondere sichergestellt werden, dass die Anzahl der falsch klassifizierten Produkte (z. B. Retouren sind verwendbar, werden aber vom Kunden entsorgt) gering gehalten wird. Im Retouren-Controlling werden bspw. Retouren nach Zustand und Verkaufsfähigkeit sortiert: A-Retouren sind einwandfrei, B-Retouren weisen leichte Gebrauchsspuren auf, C-Retouren zeigen starke Gebrauchsspuren und D-Retouren sind defekt und nicht verkaufsfähig [De21]. Die Entscheidung, ob eine Retoure verkaufsfähig ist oder nicht, kann mit Unsicherheiten behaftet sein, sodass wir mit unserem Modell die beschriebenen D-Retouren zielsicher finden wollen.

3 Ausgangslage der Case Study und Retourenprozess

Der Retourenprozess wird bei unserem Kooperationspartner mithilfe eines Retourenscheins organisiert, der aber nicht standardmäßig den Sendungen beiliegt. Kunden, die eine Retoure initiieren möchten, müssen dafür entweder den Kundenservice kontaktieren oder sich die notwendigen Dokumente über ein Onlineformular selbst beschaffen. Nachdem der Retourenschein ausgedruckt und ausgefüllt sowie das Versandlabel auf dem Paket angebracht ist, können die Kunden die Produkte kostenfrei zurücksenden. Ausgenommen von diesem Vorgehen sind Speditionsartikel, die von einer Spedition abgeholt

werden müssen. In dieser Arbeit konzentrieren wir uns auf den spezifischen Ablauf des Retourenprozesses beim Kooperationspartner, welcher das Beantragen von Retourenscheinen und den Rücktransport der retournierten Ware ins Lager umfasst. Besonderes Augenmerk liegt dabei auf jenen Fällen, in denen die zurückgesandten Produkte von den Mitarbeitenden im Lager entsorgt werden müssen.

Der gesamte Retourenprozess beeinflusst sowohl die Kundenzufriedenheit als auch die Kostenbilanz des Unternehmens negativ. Die Rückführung der Waren verursacht zum einen Mehraufwand beim Kunden (z. B. durch Ausfüllen der Retouren-Dokumente, Verpacken und Verschicken der Waren sowie Warten auf die Erstattung oder die Ersatzlieferung). Zum anderen verursacht der Rücktransport bedeutende finanzielle Belastungen für das Unternehmen aufgrund der anfallenden Transport- und Verarbeitungskosten und fügt gleichzeitig durch die entstehenden CO_2-Emissionen der Umwelt vermeidbaren Schaden zu. Diese Ausgangslage bildet die Basis für die vorliegende Case Study mit dem Ziel ein innovatives, datenbasiertes System zu entwickeln, das nicht mehr verwendbare Retouren im Vorfeld erkennt und Maßnahmen für eine ökonomische und ökologische Behandlung bereithält (vgl. Kapitel 2 und 3). Eine frühzeitige Prognose der Entsorgungswahrscheinlichkeit im kurativen Retourenmanagement senkt die Bearbeitungszeiten und Kosten von Retouren sowie die ökologischen Kosten des Rücktransports. Hinsichtlich dieser Rücktransporte verzichten wir bewusst auf die Berücksichtigung einer möglichen Optimierung durch die Zusammenführung der Rücktransporte mit anderen Lieferungen an denselben oder naheliegenden Kunden. Dies begründet sich dadurch, dass unser Kooperationspartner mit Transportdienstleistern arbeitet und auf deren Transportdaten keinen Zugriff hat, um diese Art der Analyse durchzuführen. Zudem konzentriert sich die vorliegende Untersuchung auf eine näherungsweise Ermittlung potenzieller Einsparungen. Angesichts dieser Zusammenhänge stellt sich die effektive Verringerung von vermeidbaren Retouren als Schlüsselaspekt heraus, welcher nahtlos in die Diskussion um Nachhaltigkeit und Reduzierung von CO_2-Emissionen im transportintensiven E-Commerce einfließt.

Wie die Optimierung der Retourenprozesse aufzeigt, ist die Reduktion von CO_2-Emissionen sowohl aus ökonomischer als auch aus ökologischer Perspektive hochrelevant. Etwa 5,5% der weltweiten Treibhausgasemissionen werden dem Logistiksektor zugeschrieben und 90% davon gehen auf den Transport zurück, weshalb dieser Bereich im Fokus unserer Bemühungen um Klimaschutz und Nachhaltigkeit steht [DKP24]. ISO 14083:2023 greift genau diese Problematik auf und bietet einen Rahmen für die systematische Erfassung und Reduktion von Emissionen. Die Norm fördert die Konsistenz und Vergleichbarkeit der Emissionsdaten, in dem sie die Rahmenbedingungen für die Erfassung von Treibhausgasemissionen im Transportsektor spezifiziert. Sie unterstützt darin, transparente Entscheidungen im Einklang mit Nachhaltigkeitszielen zu treffen und nachhaltigere Transportoptionen auszuwählen. Die Norm bezieht sich auf alle Transportarten und berücksichtigt die Gesamtemissionen von der Energiebereitstellung bis zu den direkten Emissionen des Fahrzeugbetriebs. Auf Basis der ISO-Norm und den Angaben unseres Kooperationspartners lässt sich für eine typische Retoure ein Ausstoß von 0,637

kg CO_2/km näherungsweise annehmen. Dabei bezieht sich unser Partner auf typischerweise zum Einsatz kommende dieselbetriebene Lieferfahrzeuge mit einer Kapazität von 3,5 Tonnen. Hier kann davon ausgegangen werden, dass ein solches Fahrzeug im Schnitt immer mit nur 50% seiner Kapazität ausgelastet ist. Mit diesen exemplarischen Angaben lässt sich der CO_2-Ausstoß einzelner Retouren näherungsweise ermitteln.

Unser Hauptziel ist es, sowohl die finanziellen Belastungen des Rücktransports als auch die damit verbundenen CO_2-Emissionen zu verringern. Wir empfehlen ein Optimierungsverfahren für den Retourenprozess, beginnend mit dem Einsatz unseres Klassifikationsmodells bei Telefonanfragen. Kunden, die telefonisch Retouren anmelden, werden hinsichtlich der Entsorgungswahrscheinlichkeit ihres Artikels überprüft. Bei hoher Entsorgungswahrscheinlichkeit raten wir dem Kunden zur Eigenentsorgung, um sowohl Kosten als auch Emissionen zu sparen. Dieser Ansatz zur Effizienzsteigerung des Retourenprozesses und zur Minimierung von unwirtschaftlichen und umweltbelastenden Rücksendungen trägt substantiell dazu bei, die Nachhaltigkeit von Wertschöpfungssystemen zu steigern.

4 Umsetzung der Case Study

Im nachfolgenden Kapitel wird die vorliegende Case Study erläutert. Zu Beginn wird der verwendete Datensatz beschrieben (vgl. Abschnitt 4.1). Daraufhin wird die Entwicklung des Klassifikationsmodell aufgeführt und das verwendete Verfahren präsentiert (vgl. Abschnitt 4.2). Abschließend folgt in Abschnitt 4.3 die Evaluation der Ergebnisse.

4.1 Vorstellung des Datensatzes

Für die Entwicklung des Klassifikationsmodells wird ein praxisrelevanter Datensatz durch den Kooperationspartner bereitgestellt. Dieser Datensatz erstreckt sich über den Zeitraum von Januar 2022 bis September 2023 und umfasst detaillierte Informationen zu Kundenrechnungen, Retouren und einzelnen zurückgesendeten Artikeln, die innerhalb dieser 20 Monate generiert wurden. Auf Basis der Kundendaten, der Rechnungsbeträge in der jeweils relevanten Währung, der gewählten Zahlungsmethoden und der genutzten Vertriebskanäle lässt sich zunächst das Verständnis der finanziellen Aspekte der Retouren erarbeiten. Im Datensatz sind darüber hinaus Kosten für die Retourenbearbeitung und den Transport über unterschiedliche Dienstleister enthalten. Neben den finanziellen Informationen umfassen die Daten wichtige Rücksendungsdetails, wie das Datum der Retoure, die Zeitspanne zwischen Versand und Retoure sowie der spezifische Rücksendegrund. Eine besondere Rolle spielt die Anzahl retournierter Artikel und ihre Verarbeitung innerhalb des Unternehmens, wobei wir unter anderem zwischen der Einlagerung zurückgekehrter Waren, der Zustellung von Ersatzgütern und der Entsorgung unterscheiden. Insgesamt ermöglicht uns der Datensatz eine Analyse von 187.690 Kundenrechnungen, aus denen schlussendlich 201.750 Retourenvorgänge resultierten,

welche sich wiederum auf 297.915 einzelne zurückgesendete Artikel aufteilten. Um unsere Analyse zu präzisieren, werden atypische Rücksendegründe wie „Verschollene Lieferung“ oder „Rückläufer“ aus den Daten herausgefiltert, da solche Fälle nicht vom Kunden veranlasste Rücksendungen sind.

Um zu ermitteln, ob es Zusammenhänge zwischen dem retournierten Produkt und den anderen Produktgruppen innerhalb der Bestellung gibt, wird auf Ebene der Produkthauptgruppe (z. B. Küchenutensilien, Möbel, Lichttechnik) einer Retoure ausgewertet, ob diese gemeinsam mit unterschiedlichen Produkthauptgruppen versendet wurde. Die Bestellsumme könnte ebenfalls Einfluss auf die Entsorgungswahrscheinlichkeit haben und wird daher auch pro Retoure ermittelt, ebenso wie die Marge des retournierten Produkts aus Einkaufs- und Verkaufspreis. Für die numerischen Attribute wurden weiterhin automatisiert weitere Features abgeleitet. Hier sind z. B. Features aufgrund von einfachen mathematischen Transformationen, z. B. quadrieren oder Anwenden der Exponentialfunktion, zu nennen. Zudem werden erste Hauptkomponenten ermittelt, die in der Hauptkomponentenanalyse mindestens 30% der Informationen enthalten, und es wurde die Distanz zum nächstgelegenen Cluster nach einer einfachen Clusteranalyse mit *k*-means (hier mit k=4) bestimmt.

Nach der Auswahl der Features und der Datenbereinigung konnten schlussendlich 274.501 retournierte Produkte berücksichtigt werden. Das sind monatlich etwa 13.000 Produkte, die im Lager zu bearbeiten sind. Dabei ist auffällig, dass insbesondere in den Wintermonaten eine stark erhöhte Anzahl an Retouren festzustellen ist, die jedoch auch mit der Anzahl aller Bestellungen in diesem Zeitraum korreliert. Die Verteilung der Zielvariablen ist über die Zeit relativ konstant und liegt insgesamt bei 55,8% für die entsorgten Retouren gegenüber 44,2% für die wiedereingelagerten Retouren. Somit können im Folgenden Trainings- und Testdatensätze zufällig und ohne Berücksichtigung eines Bias aus dem gesamten Zeitraum gezogen werden.

4.2 Entwicklung des Klassifikationsmodells

Die Erstellung eines Klassifikationsmodells erfolgt auf Basis der Open Source Software KNIME. Die No-Code/Low-Code-Plattform sticht insbesondere durch eine intuitive grafische Benutzeroberfläche und vordefinierte Knoten für Datenaufbereitung, -transformation, -analyse und Visualisierung hervor [Fi17]. Dadurch ist sie besonders für Klein- und mittelständische Unternehmen geeignet, die nicht über passende Mitarbeitende mit Programmiererfahrung oder tiefergehenden Data Science-Kenntnissen verfügen. Wir nutzen die Plattform, um das Modellergebnis beim Kooperationspartner ohne größeren Schulungsaufwand in die Umsetzung bringen zu können. Erste Tests mit unterschiedlichen Klassifikationsverfahren ergaben, dass die Trainings- und Testgüte von Gradient Boosted Trees (GBT) vor allem im Vergleich zu ähnlich komplexen Modellen wie dem Random Forest oder komplexeren Modellen wie Neuronalen Netzen deutlich überwog. Daher fokussieren wir uns bei der finalen Modellierung des Klassifikationsmodells auf GBT. Hierbei handelt es sich um einen Ensemble-Ansatz, bei dem mehrere schwache,

leicht zu trainierende Modelle, d. h. Entscheidungsbäume wie CART, gemeinsam eine Zielvariable vorhersagen. Der Algorithmus wird sequentiell in einem Gradientenabstiegsverfahren trainiert und minimiert dabei eine Verlustfunktion durch Hinzunahme weiterer Lerner. Diese basieren auf den Residuen der vorherigen Modelle und versuchen gezielt, die fehlerhaft klassifizierten Datensätze aus der vorherigen Iteration besser zuzuordnen. Die Lernrate gibt dabei an, wie stark der Gradientenabstieg sein soll [FYZ18].

Nach der Vorauswahl von GBT werden zunächst mit einer 10-fachen Kreuzvalidierung die passenden Hyperparameter ausgewählt. Für jeden Iterationsschritt in der Kreuzvalidierung wird auf dem jeweiligen Trainingsdatensatz ein Parameter-Tuning mit Zufallssuche in 100 Iterationen vorgenommen. Die Parameter werden mit jeweils passenden Start- und Endwerten iteriert, d. h. *num_trees*(*50*, *200*), *max_depth*(*3*, *20*) sowie *learn_rate*(*0.1*, *0.3*). Als zu minimierende Verlustfunktion wählen wir die Genauigkeit (d. h. accuracy), also der Anteil der korrekt klassifizierten Retouren, da die Zielvariable nahezu gleichverteilt ist und somit komplexere Gütemaße, die üblicherweise eine Ungleichverteilung der Zielvariable stärker berücksichtigen, nicht erforderlich sind. Die ermittelten Hyperparameter werden dann verwendet, um einen GBT zu trainieren. Die Aufteilung in Trainings- und Testdaten erfolgt dabei so, dass im Testdatensatz ca. 39.000 Retouren enthalten sind, was dem durchschnittlichen Retourenaufkommen von drei Monaten nach Anwendung der fachlichen Filter (siehe Abschnitt 4.1) entspricht.

- **Maximale Anzahl Modelle**: 126 (*num_trees*), entspricht der Anzahl an Iterationen zur Verbesserung des gesamten Modells. Wenn zu viele Iterationen durchgeführt werden, besteht hier die Gefahr des Overfittings. Das finale Modell besteht aus 69 Bäumen, da zur Reduktion der Trainingszeit ein Abbruchkriterium auf Basis der vorhandenen Fehlklassifikationen eingeführt wurde.
- **Maximale Baumtiefe**: 17 (*max_depth*), ermöglicht komplexere, besser an die Daten angepasste Modelle, wenn tiefere Bäume zugelassen werden. Allerdings kann auch dies zu Overfitting und einer längeren Trainingsdauer führen. Das finale Modell weist eine durchschnittliche Baumtiefe von 16,75 auf, wobei im Mittel 5.716 Blattknoten erzeugt werden. Das Modell scheint daher relativ komplex und stark an die Trainingsdaten angepasst.
- **Lernrate**: 0,191 (*learn_rate*), je geringer die Schrittweite der Verbesserung, desto wahrscheinlicher wird ein gutes Modell erstellt. Allerdings wird auch eine höhere Anzahl an Iterationen notwendig. Eine zu hohe Lernrate kann dazu führen, dass das Minimum nicht gefunden wird.
- **Threshold**: 0,519, jede Retoure erhält einen Score-Wert, der der Sicherheit des Modells entspricht, mit dem die Retoure zur Klasse „*Nicht verwendbar*“ gehört. Bei einem Score unterhalb des Schwellwerts gibt das Modell die Klasse „Sonst“ zurück, darüber wird „*Nicht verwendbar*“ zurückgegeben. Der Threshold kann bei Bedarf angepasst werden, um den Anteil der Fehlklassifikationen in eine betriebswirtschaftlich gewünschte Richtung zu verändern.

4.3 Evaluation des Modells

Tabelle 1 zeigt, welche Features im finalen Klassifikationsmodell besonders einflussreich für die Entscheidung über die Ausprägung der Zielvariablen sind. Insbesondere die Artikelgruppe, die Farbe und der Hersteller fallen dabei auf. Es handelt sich um Features mit einer großen Anzahl an Ausprägungen, was bei Klassifikationsverfahren unter Umständen zu Overfitting führen kann. Daher wurden die Features noch einmal gesondert untersucht. Es lässt sich feststellen, dass der Anteil der entsorgten Produkte bei einigen Ausprägungen der drei Features jeweils extrem erhöht ist. Einzelne Hersteller, bestimmte Produktgruppen und -farben werden in über 90% der Fälle entsorgt, während andere in über 90% der Fälle in den Wiederverkauf gehen. Im engen Austausch mit dem Kooperationspartner stellte sich heraus, dass einzelne Hersteller und Produktgruppen bereits als stark „entsorgungsanfällig“ bekannt sind.

Features	**Relevanz**	**Prozentuale Relevanz**	**Anzahl Ausprägungen**
Produktuntergruppe	1,000	36,64%	653
Farbe	0,538	19,59%	370
Hersteller	0,490	17,84%	361
Einkaufspreis Item	0,084	3,05%	numerisch
Wochentag Versand	0,044	1,58%	7
Verkaufspreis	0,039	1,41%	numerisch
Monat Versand	0,032	1,18%	12
Kundengruppe	0,032	1,15%	24
Marge Item	0,031	1,12%	numerisch
Zahlweise	0,029	1,06%	10

Tab. 1: Wichtigste Features des finalen Modells

Um die Robustheit des Modells zu prüfen, wurden Datensätze, deren Hersteller, Produktgruppe oder -farbe in mehr als 90% der Fälle entsorgt respektive wiedereingelagert werden, als eine Art Ausreißer aus dem Trainings- und Testdatensatz entfernt und sowohl Training als auch Test des Modells mit den bekannten Parametern wiederholt. Tabelle 2 zeigt, dass sich die Güte des Modells kaum verschlechtert [ZAA22]. Interessant ist dabei, dass die „Precision“ des Modells (d. h., korrekte Vorhersage der Klasse im Verhältnis zur Anzahl der Vorhersagen der Klasse) abnimmt, während der „Recall“ (d. h., die Anzahl der korrekt vorhergesagten Klasse im Verhältnis zu den vorhandenen Produkten einer Klasse) gleich bleibt.

Güte-Maß	inkl. Ausreißer	ohne Ausreißer
RMSE	0,249	0,258
Accuracy	0,920	0,913
Precision	0,927	0,907
Recall	0,930	0,930
F1	0,928	0,918

Tab. 2: Modellstatistik der Testdaten beim Training mit und ohne Ausreißer

Neben der technischen Evaluation des Modells, die mit einer Accuracy von 0,92 sehr gut ausfällt, ist es vor allem von Interesse, welche ökonomischen und ökologischen Auswirkungen die Fehlklassifikationen des Modells haben. Nur dann ist es möglich, das Risiko des Einsatzes eines automatisierten Eingriffs in den Retourenprozess abzuschätzen. Hierbei spielt die Betrachtung der Opportunitätskosten eine maßgebliche Rolle, da sie es ermöglichen, die finanziellen Konsequenzen betreffender Fehlklassifikationen zu quantifizieren. Opportunitätskosten bezeichnen Einbußen aufgrund nicht genutzter, vorteilhafte Handlungsoptionen, die sowohl aus entgangenen Verkaufserlösen durch fälschlich als „*Nicht verwendbar*“ eingestufte Artikel (False Positives) als auch aus unnötigen Transport und Prozesskosten für irrtümlich als verkaufsfähig klassifizierte Produkte (False Negatives) resultieren. Hinzu kommen ökologische Opportunitätskosten, die den Umweltschaden der Fehlklassifikation durch CO_2-Emissionen abbilden [Co11]. Tabelle 3 zeigt die resultierende Konfusionsmatrix, die auf den zufälligen 39.000 Testdaten basiert.

	Nicht verwendbar (*vorhergesagt*)	**Sonst** (*vorhergesagt*)	
Nicht verwendbar (*faktisch*)	20.299	1.642	**Sensitivity** 0,925163
Sonst (*faktisch*)	1.506	15.553	**Specificity** 0,911718
	Precision 0,930933	**NPV** 0,904507	

Tab. 3: Konfusionsmatrix (39.000 Testdaten)

False Negatives (1.642 Retouren): Das Modell sagt eine Wiedereinlagerung des Produkts voraus, tatsächlich wird es jedoch bei Ankunft im Lager entsorgt. Hier entstehen entsprechende Kosten durch den Transport zum Lager und die Bearbeitung. Die Transportkosten variieren je nach gewählter Versandart, dem beauftragten Logistikdienstleister und dem Zielland der Lieferung. Im Lager angekommen, fallen Bearbeitungskosten an, die in einer Pauschale für die Überführung der Ware vom LKW zum Bearbeitungstisch und für die Zeit des Auspackens berücksichtigt werden (a), wobei angenommen wird, dass diese 50% der durchschnittlichen Behandlung von nicht verwendbaren Retouren ausmachen. Zusätzlich sind die Kosten für die Bearbeitungsdauer zu kalkulieren, welche sich aus dem Zeitaufwand für die Bearbeitung und den damit verbundenen

Lohnkosten zusammensetzen (b). Schließlich wird für das Abräumen und den Transport der Ware von der Bearbeitungsfläche zur Entsorgung ebenso ein pauschaler Kostensatz angesetzt (c), der wiederum 50% der mittleren Bearbeitungskosten aller nicht verwendbaren Retouren entspricht. Tabelle 4 zeigt eine Aufstellung der Aufwände der False Negatives. Insgesamt ergeben sich etwa 30.000 € Kosten für Transport und Bearbeitung der unnötigen Retouren. Aus Datenschutzgründen können wir die Distanzen lediglich auf Basis der in den Daten enthaltenen Postleitzahlen der Kunden schätzen. Damit kommen wir auf einen CO_2-Ausstoß von knapp 350 Tonnen für die fehlerhaft vorhergesagten Retouren. Hierbei ist zu beachten, dass von den 1.642 Retouren lediglich 1.458 Retouren aus Deutschland, Österreich und der Schweiz kommen und nur für diese eine genauere Berechnung der Distanz und der CO_2-Werte erfolgt. Für die übrigen Retouren wird die mittlere Distanz aller Retouren angenommen und der CO_2-Ausstoß geschätzt, weshalb von einer deutlichen Unterschätzung auszugehen ist.

(Anzahl False Negatives: 1.642 Retouren)	**Mittelwert**	**Summe**
Transportkosten	10,10 €	15.889,00 €
Bearbeitungskosten (a)	2,98 €	4.687,54 €
Bearbeitungskosten (b)	2,49 €	3.916,26 €
Bearbeitungskosten (c)	2,98 €	4.687,54 €
Distanz zum Lager	345,59 km	543.619,06 km
Menge CO_2	220,14 kg	346.285,34 kg

Tab. 4: Ökonomische und ökologische Aufwände der False Negatives

False Positives (1.506 Retouren): Das Modell sagt für das Produkt die Entsorgung voraus, tatsächlich ließe es sich aber wieder einlagern und weiterverkaufen. Hier ermitteln wir den wirtschaftlichen Schaden, der durch die nicht erfolgte Einnahme des Verkaufspreises bzw. den Verlust des Einkaufspreises entsteht. In Tabelle 5 ist angegeben, auf welche Summen sich Marge, Einkaufs- und Verkaufspreis für die fälschlicherweise als „*Nicht verwendbar*“ klassifizierten Retouren belaufen. Es ist zu berücksichtigen, dass bei einer korrekten Vorhersage der Transport, die Bearbeitung im Lager sowie der CO_2-Ausstoß zu berücksichtigen wären.

(Anzahl False Positives: 1.506 Retouren)	**Mittelwert**	**Summe**
Marge	53,02 €	89.391,50 €
Einkaufpreis	59,53 €	100.360,27 €
Verkaufspreis	112,62 €	190.770,11 €

Tab. 5: Opportunitätsverluste der False Positives

Anhand der in Tabelle 5 dokumentierten Werte belaufen sich die aggregierten Opportunitätskosten für False Positives auf einen Verkaufspreisverlust von 190.770 €. Die quantifizierten Gesamtkosten und CO_2-Emissionen unterstreichen die Notwendigkeit einer möglichst genauen Klassifikation, um sowohl die direkten finanziellen Verluste zu minimieren, als auch die Umweltbelastungen zu reduzieren, die langfristig sowohl die

Natur als auch das Image und die soziale Verantwortung des Unternehmens beeinträchtigen könnten.

5 Auswirkungen auf das Unternehmen und die Branche

Die Implementierung unseres Klassifikationsmodells beim Kooperationspartner adressiert die Senkung von CO_2-Emissionen im Zuge des Retourenmanagements. Die möglichen Einsparungen betonen den Wert von effektiven Retourenprozessen für die Umwelt und das Betriebsergebnis (vgl. Abschnitt 5.1). Zusätzlich bewirkt die Einführung des Modells eine positive strategische Neupositionierung des Unternehmens innerhalb des nachhaltigen E-Commerce, was durch eine Erhöhung der Kundenattraktivität und ein gestärktes Umweltimage ergänzt wird (vgl. Abschnitt 5.2). Abschnitt 5.3 geht auf den Einsatz des Modells im Online-Möbelhandel ein.

5.1 Auswirkungen von Retouren auf CO_2-Emissionen im Transport

Wenn das Klassifikationsmodell beim Kooperationspartner zum Einsatz kommt, kann durch die Nicht-Rücksendung von zu entsorgenden Produkten CO_2 eingespart werden. Diese Auswirkungen quantifizieren wir gemäß der in Kapitel 3 vorgestellten Annahmen. Wir gehen für die näherungsweise Berechnung von einem Ausstoß von 0,637 kg CO_2/km für ein dieselbetriebenes 3,5-Tonnen-Lieferfahrzeug mit halber Auslastung aus. Die Annahmen zum Transportweg basieren auf der Prämisse, dass dieser über kurze bis mittlere Distanzen via Landwege erfolgt, was durch Angaben unseres Kooperationspartners gestützt wird. Dieser bestätigt, dass auf solchen Strecken Luft- oder Wasserwege nicht genutzt werden. Wir gehen davon aus, dass die in den Testdaten (Retourenaufkommen von ca. 3 Monaten) als „*Nicht verwendbar*“ vorhergesagten Retouren tatsächlich beim Kunden entsorgt werden. Dann müssten 22.645 Retouren nicht transportiert werden (True Positives und False Positives). Von den jeweiligen Retouren entfallen 16.575 auf deutsche, österreichische und Schweizer Kunden, die wir nun weiterhin betrachten. Als Berechnungsgrundlage für die Entfernungen ermitteln wir die kürzeste Distanz zwischen dem Postleitzahlengebiet des Kunden und dem des Retourenlagers unseres Kooperationspartners und schätzen die Transportstrecke damit sehr optimistisch. Innerhalb von drei Monaten ließen sich dementsprechend bei Retouren mindestens 4.463.346 km und 2.843.151 kg CO_2 einsparen. Die Ergebnisse dieser Betrachtung zeigen deutlich, dass die Maßnahmen (Entsorgung beim Kunden) zur Reduktion von Retouren und zur Verbesserung der Nachhaltigkeit im Onlinehandel führt.

5.2 Strategische, nachhaltige Positionierung des Unternehmens

Mit der Implementierung des vorliegenden Klassifikationsmodells ordnet sich unser Kooperationspartner im Bereich des nachhaltigen E-Commerce ein. Diese progressive

Ausrichtung ermöglicht dem Unternehmen, auf Kundinnen und Kunden attraktiv zu wirken, die zunehmend Wert auf ökologische Verantwortlichkeit und ethisches Konsumverhalten legen. Durch eine effizientere Handhabung von Retouren und die Reduzierung von Produktentsorgungen stärkt das Unternehmen sein Profil als umweltbewusste Marke. Dies fördert nicht nur das Kundenvertrauen, sondern korrespondiert auch mit den Zielen vieler Stakeholder, die nachhaltige Geschäftsmodelle unterstützen.

Die strategische Neuausrichtung geht zudem einher mit der Anwendung datengetriebener Lösungen in der Praxis. Daten sind die Grundlage für eine tiefgehende Analyse und Vorhersage von Kundenverhalten und Produktschicksal nach der Retoure. Aus diesen Erkenntnissen heraus kann das Unternehmen nicht nur beträchtliche finanzielle Einsparungen realisieren, sondern auch seine Marktposition durch ein verbessertes Image und eine gute Kundenbindung stärken. Daraus resultiert eine Win-Win-Win-Situation für das Unternehmen, seine Kunden und die Umwelt.

5.3 Einsatz des Modells im Online-Möbelhandel

Insbesondere die positiven Aspekte für Unternehmen, Kunden und Umwelt können erhöht werden, wenn der hier vorgestellte Ansatz nicht nur bei einem Unternehmen zum Einsatz kommt, sondern auf die gesamte Online-Möbelbranche übertragen wird. Ein Vorteil bei der unternehmensübergreifenden Anwendung des Ansatzes wäre, dass sowohl große als auch kleine und mittelständische Unternehmen von den positiven Auswirkungen profitieren und gleichzeitig nachhaltiger handeln können. Gerade kleinere Onlinehändler könnten allerdings bei der Anwendung des Ansatzes Schwierigkeiten haben, wenn keine hinreichende Datengrundlage für das Training des Modells zur Verfügung steht. Es ist zu überlegen, ob im Rahmen einer Kooperation eine - anonymisierte - Bündelung der Retourendaten verschiedener Unternehmen erfolgen kann, auf deren Basis dann ein gemeinsames Modell trainiert wird. Vorteilhaft ist zudem, dass dem Modell beim Training mehr Variationen in den Daten vorgelegt werden, wodurch eine Steigerung der Robustheit der Klassifikationsgüte zu erwarten ist. Durch die Nutzung der Low-Code-Technologie in der Entwicklung wird eine Möglichkeit der Bereitstellung und Anwendung des Modells für alle Kooperationspartner, auch ohne technisches Know-how, bereits jetzt unterstützt. Hierbei ist jedoch zu beachten, dass Geschäftsgeheimnisse anonymisiert werden müssen, was eine kritische Auseinandersetzung erfordert. Es stellt sich die Frage, inwieweit ein Datenaustausch umsetzbar ist, ohne die Nützlichkeit des Modells zu beeinträchtigen.

Zu berücksichtigen ist, dass bei einer betrügerischen Nutzung des Systems, bei der Kunden gezielt Retouren initiieren, um die Waren trotz Erstattung zu behalten, dem Unternehmen ein Schaden entsteht. Dieser zeichnet sich dadurch aus, dass wiederverkaufsfähige Ware unrechtmäßig beim Kunden verbleibt und vom Unternehmen erstattet wird. Um dem entgegenzuwirken könnte es sinnvoll sein, die individuellen Kundenumsätze zu bereinigen und zu überprüfen. Dies könnte Hinweise auf ein solches Verhalten liefern. Bei einer negativen Entwicklung, wie bspw. einem insgesamt geringen

Umsatz trotz häufiger Bestellungen, kann festgestellt werden, ob ein Kunde möglicherweise übermäßig viele Retouren tätigt. In einem solchen Fall könnte eine restriktivere Rückgabepolitik angewendet werden, indem die ausgelieferten Waren häufiger zurückgefordert werden. Die Notwendigkeit dieses Vorgehens ergibt sich aus der Tatsache, dass unsachgemäße Retourenanfragen die Wirtschaftlichkeit von Unternehmen beeinträchtigen und die Attraktivität des vorgestellten Ansatzes für Unternehmen mindern könnten. Eine weitere Möglichkeit in diesem Zusammenhang wäre die Adaption eines der in Ke20 vorgestellten Vorhersagemodelle, die bei einem solchen Verhalten ein unternehmensseitiges Eingreifen ermöglichen, mit dem Ziel, den Aspekt von missbräuchlich eingeleiteten Retouren durch die Kunden zu eliminieren.

6 Fazit und Ausblick

Die vorliegende Case Study veranschaulicht das Potenzial von Klassifikations- und datengetriebenen Modellen bei der Realisierung eines effizienten und nachhaltigen Retourenmanagements in Unternehmen. Das speziell auf Basis von Gradient Boosted Trees entwickelte Klassifikationsmodell hat in dieser Case Study eine signifikante Prozessoptimierung ermöglicht, was unserem Kooperationspartner dabei hilft, seinen ökologischen Fußabdruck wesentlich zu verringern. Hinsichtlich des weiteren Vorgehens könnte eine strategische Überlegung darin bestehen, die Praktiken rund um die Rücksendung der Produkte anzupassen, um den Retourenprozess weiter zu verfeinern. Beispielsweise könnte das Modell auch in die Online-Option für Retourenanfragen integriert werden, um die Kontrolle über die Retouren und Entsorgungsprozesse zu verbessern. Eine Betrachtung der langfristigen Umweltauswirkungen, der Marktpositionierung des Unternehmens und der Wettbewerbsfähigkeit der Branche nach der Anwendung des Modells kann konkrete Handlungsempfehlungen für eine langfristig nachhaltige und effiziente Retourenstrategie liefern. Die Analyse potenzieller Risiken und Chancen im Rahmen der Modellimplementierung bietet Unternehmen die Möglichkeit, fundierte Entscheidungen zu treffen, um ihre Prozesse langfristig zu optimieren und gleichzeitig ihre ökologische und wirtschaftliche Nachhaltigkeit zu stärken. Die Ergebnisse verdeutlichen die breite Anwendbarkeit der Methodik, wobei zukünftig eine Erweiterung des Modells durch die Integration zusätzlicher Datenquellen erfolgen kann. Für Unternehmen, die bereit sind, in innovative Technologien zu investieren, ergeben sich strategische Vorteile, die eine starke Positionierung im wachsenden Markt eines nachhaltigen E-Commerce möglich machen.

Diese Arbeit zeichnet sich durch mehrere Merkmale aus, welche die Bedeutung dieser Studie im Rahmen des Retourenmanagements im E-Commerce besonders hervorheben. Ein zentraler Schwerpunkt liegt auf der Entwicklung des Klassifikationsmodells, das darauf abzielt, die Verwertbarkeit von Retouren zu prognostizieren und somit potenzielle ökonomische und ökologische Einsparungen zu identifizieren und zu realisieren. Im Unterschied zu anderen Studien, die oft präventive Ansätze verfolgen, um Retouren zu vermeiden, setzt diese Arbeit auf einen kurativen Ansatz, der einen optimierten Umgang

mit bereits initiierten Retouren anstrebt. Durch die gezielte Vorhersage der Verwertbarkeit von Retouren wird eine effizientere Entsorgungspolitik angestrebt, welche die Kunden einbezieht, im Gegensatz zur reinen Konzentration auf monetäre Maßnahmen zur Vermeidung von Retouren.

Die enge Zusammenarbeit mit unserem Kooperationspartner sowie die Entwicklung und Evaluierung des Modells bieten vielversprechende Ansätze zur Optimierung der Retourenprozesse. Diese Maßnahmen könnten dazu beitragen, ein ganzheitliches System für effizientes Retourenmanagement in der Möbelbranche zu etablieren.

In dieser Studie wird besonders die gezielte Vorhersage der Verwertbarkeit von Retouren und der Fokus auf bereits initiierte Rücksendungen als innovativer Ansatz hervorgehoben, der sowohl ökonomische als auch ökologische Vorteile ermöglicht. Die praxisorientierte Ausrichtung auf eine effiziente Entsorgungspolitik und die Berücksichtigung potenzieller Limitationen in der Modellentwicklung bilden zentrale Aspekte dieser Arbeit, die als Impulsgeber für zukünftige Forschungsvorhaben im Bereich des Retourenmanagements im E-Commerce dienen können.

Literaturverzeichnis

[AK22] Asdecker, B.; Karl, D.: Shedding some light on the reverse part of e-commerce: A systematic look into the black box of consumer returns in Germany. European Journal of Management, 22/1, S. 59–81, 2022.

[AKS21] Asdecker, B.; Karl, D.; Sucky, E.: Retourenmanagement als Erfolgsfaktor des Handels. In (Schallmo, D. R. A.; Rusnjak, A.; Anzengruber, J.; Werani, T.; Lang, K., Hrsg.): Digitale Transformation von Geschäftsmodellen, Schwerpunkt Business Model Innovation, S. 605–622. Springer Fachmedien, Wiesbaden, 2021.

[As14] Asdecker, B.: Retourenmanagement im Versandhandel: theoretische und empirisch fundierte Gestaltungsalternativen für das Management von Retouren. Dissertation, Otto-Friedrich-Universität, Bamberg, 2014.

[AS18] Asdecker, B.; Sucky, E.: Das Retourenmanagement im interaktiven Handel. In (Corsten, H.; Gössinger, R.; Spengler, T. S., Hrsg.): Handbuch Produktions- und Logistikmanagement in Wertschöpfungsnetzwerken., S. 294–308. De Gruyter Oldenbourg, München und Wien, 2018.

[Co11] Conway, E.: Opportunitätskosten. In: Wirtschaftswissenschaft, S. 18–21. Spektrum Akademischer Verlag, Heidelberg, 2011.

[De16] De Leeuw, S. et al.: Trade-offs in managing commercial consumer returns for online apparel retail. International Journal of Operations & Production Management, 36/6, S. 710–731, 2016.

[De21] Deges, F.: Retourencontrolling im Online-Handel. Controlling, 33/2, S. 61–68, 2021.

[DKP24] Deckert, C.; Kretschmar, D.; Plagge, C.: Auf einen gemeinsamen Nenner gebracht? – Reporting der Treibhausgas-Emissionen der Logistikunternehmen in Deutschland. Bericht, Hochschule Düsseldorf, 2024.

[DL16] Drechsler, S.; Lasch, R.: Forecasting Misused E-Commerce Consumer Returns. In (Mattfeld, D.; Spengler, T.; Brinkmann, J.; Grunewald, M., Hrsg.): Logistics Management, S. 203–215. Springer International Publishing, Cham, 2016.

[Fi17] Fillbrunn, A. et al.: KNIME for Reproducible Cross-Domain Analysis of Life Science Data. Journal of Biotechnology, 261, S. 149–156, 2017.

[FL21] Fuchs, K.; Lutz, O.: A stitch in time saves nine – A meta-model for real-time prediction of product returns in ERP systems. In: Proc. 29th European Conference on Information Systems, Marrakech, Morocco, 2021.

[FYZ18] Feng, J.; Yu, Y.; Zhou, Z.-H.: Multi-Layered Gradient Boosting Decision Trees. In (Bengio, S.; Wallach, H.; Larochelle, H.; Grauman, K.; Cesa-Bianchi, N.; Garnett, R., Hrsg.): Advances in Neural Information Processing Systems 31, 2018.

[Ka24] Karl, D.: Forecasting e-commerce consumer returns: a systematic literature review. Management Review Quarterly, 2024.

[Ke20] Ketzenberg, M. et al.: Assessing customer return behaviors through data analytics. Journal of Operations Management, 66/6, S. 622–645, 2020.

[Wa14] Walsh, G. et al.: Preventive product returns management systems: A review and a model. In: Proc. 22nd European Conference on Information Systems, Tel Aviv, 2014.

[ZAA22] Zhu, H.; Azarafza, M.; Akgün, H.: Deep learning-based key-block classification framework for discontinuous rock slopes. Journal of Rock Mechanics and Geotechnical Engineering, 14/4, S. 1131–1139, 2022.