

In-Store Customer Analytics – Metriken & Reifegradszenarien zur Erfassung physischer Kundenkontakte im stationären Einzelhandel

Lars Bollweg¹, Richard Lackes², Markus Siepermann³ und Peter Weber⁴

Abstract: Im Gegensatz zu der im Online-Handel etablierten Erfassung und Auswertung der Kundenkontaktdaten über den Browser (Web Analytics) vernachlässigt der stationäre Handel die Analyse der physischen Kundenkontakte im Ladenlokal (In-Store Customer Analytics) bisher weitgehend und fokussiert sich stattdessen auf die Auswertung von Transaktionsdaten. Dabei hat sich gerade die Erfassung und Auswertung der transaktionsvorgelagerten Kundenkontaktdaten zu einem zentralen Instrument der systematischen Weiterentwicklung und Verbesserung des Online-Handels entwickelt, so z. B. zur Landingpage- und Conversion-Optimierung. Die Analyse von Kundenkontaktdaten lässt entsprechend auch große Potenziale für den stationären Handel vermuten. Der vorliegende Beitrag systematisiert vor diesem Hintergrund auf Basis einer Literaturanalyse die mess- und übertragbaren In-Store Customer-Metriken und setzt diese in einer Kundenerfassungs-Reifegrad-Matrix in Bezug zu den für die Erfassung zur Verfügung stehenden Technologien.

Keywords: In-Store Customer Analytics, Metriken, Kundenerfassungs-Reifegrad-Matrix

1 Einleitung

Im Gegensatz zum stationären Handel ist die Erfassung und Auswertung von Kundenkontaktdaten im Online-Handel (Web Analytics) etablierte Praxis [DFK02]. Die online erhobenen Kundenkontaktdaten werden mit den Transaktionsdaten im Shopsystem abgeglichen und so z.B. die erzielten Verkäufe (Transaktionen) mit den potenziellen Verkäufen (Besucher auf der Webseite) in Beziehung gesetzt (sog. Conversion Rate). Diese Web-Analytics verfolgen das Ziel, durch eine datenbasierte und damit bedarfsgerechte Anpassung der Seitenstruktur, des Designs, des Angebots, der Preisstrategien usw. die Anzahl der Verkäufe zu erhöhen, und gehören faktisch zum Tagesgeschäft in jedem professionell betriebenen Online-Handel [DML11]. Im Gegensatz dazu sind die Kundenkontakte im Ladenlokal für den stationären Einzelhandel in weiten Teilen eine Black-Box [Ge14]. Auch wenn bereits seit Jahrzehnten Strategien zur Analyse der Kundenkontakte im Handel entwickelt und untersucht werden (z.B. über manuelle Zählungen, Testkunden und Eye-Trackingverfahren oder auch Modellierungsansätze wie das Blueprinting) [Gr68] [BD95] [NJ99] [Bi10], hat sich eine (teil-)automatisierte Erfassung

¹ Fachhochschule Südwestfalen, Lübecker Ring 2, 59494 Soest, bollweg.lars@fh-swf.de

² TU Dortmund, Otto-Hahn-Str. 12, 44227 Dortmund, richard.lackes@tu-dortmund.de

³ TU Dortmund, Otto-Hahn-Str. 12, 44227 Dortmund, markus.siepermann@tu-dortmund.de

⁴ Fachhochschule Südwestfalen, Lübecker Ring 2, 59494 Soest, weber.peter@fh-swf.de

und Analyse von Kundenkontaktdaten (In-Store Customer Analytics) im stationären Handel bisher nicht durchsetzen können. Ganz im Gegenteil, Händler und Forschung konzentrieren sich mit Bezug zum stationären Handel primär auf die reine Auswertung von Transaktionsdaten und vernachlässigen damit die Möglichkeit, über die Einbeziehung von Kundenkontaktdaten ihren Analyse-Horizont voll auszuschöpfen [BK12] [Su15]. Dies mag auf der einen Seite daran liegen, dass wir uns in einer Phase des Übergangs befinden, in der umfassende Lösungen noch kostenintensiv, fehleranfällig und bisher nur schwer in die bestehenden Infrastrukturen zu integrieren sind [GC05]. Auf der anderen Seite aber stehen bereits eine Vielzahl von Technologien mit unterschiedlichen Reifegraden zur Erhebung und Auswertung von Kundenkontaktdaten im Ladenlokal zur Verfügung. Es fehlt jedoch derzeit noch an einer strukturierten, technologieübergreifenden Auseinandersetzung mit den Grundlagen der Kundenkontaktdatenerfassung und -analyse. Vor diesem Hintergrund widmet sich der vorliegende Beitrag mit Hilfe einer strukturierten Literaturliteraturanalyse der Aufarbeitung der Grundlagen zu Fragestellungen der In-Store Customer Analytics und der Beantwortung der folgenden Forschungsfragen:

- RQ1:** *Welche bestehenden Technologien zur Kundenkontaktdatenerfassung im Ladenlokal stehen dem Handel zur Verfügung?*
- RQ2:** *Welche In-Store Customer Metriken können im Ladenlokal erfasst werden?*
- RQ3:** *Welche Erfassungstechnologien können welche In-Store Customer Analytics Metriken erfassen?*

Dieser Beitrag betrachtet die Erfassungstechnologien autonom und konzentriert sich auf die von Kundenkontakten ableitbaren Metriken. Verknüpfungen zu Transaktionsdaten werden bewusst nicht betrachtet, um den Fokus auf die Kundendatenerfassung zu erhalten. Der Beitrag gliedert sich wie folgt: In Abschnitt 2 wird in einem ersten Teil die Strukturierung der Web Analytics-Metriken (nach der Web Analytics Association [We16]) diskutiert, um im weiteren Verlauf des Beitrages eine den identifizierten Kategorien angepasste Sammlung von In-Store Customer Analytics Metriken abzuleiten. Im zweiten Teil wird mit Hilfe einer strukturierten Literaturliteraturanalyse der aktuelle Stand der Forschung zur Kundenkontaktdatenerfassung erhoben und die bereits im Einsatz befindlichen Technologien, sowie die damit messbaren In-Store Customer Metriken werden kategorisiert und erfasst. In Abschnitt 3 werden die erhobenen Erfassungstechnologien darauf aufbauend unter Berücksichtigung ihrer individuellen technologischen Entwicklung strukturiert und in Bezug auf ihre Leistungsfähigkeit diskutiert. In Abschnitt 4 werden die erhobenen In-Store Customer Analytics Metriken zur Komplexitätsreduktion auf eine Sammlung von Kernmetriken reduziert, um diese in Abschnitt 5 in einer Kundenerfassungs-Reifegrad-Matrix zusammenzuführen und damit einen strukturierten Überblick über die verfügbaren Erfassungstechnologien und die über sie erfassbaren Metriken zu bieten. In Abschnitt 6 werden die resultierenden Implikationen für die Praxis diskutiert, bevor der Beitrag in Abschnitt 7 mit einem Fazit und einem Ausblick abgeschlossen wird.

2 Literaturanalyse

Die hier durchgeführte Literaturanalyse gliedert sich in zwei Teile. Der erste Teil widmet sich den in der Web-Analyse bereits etablierten Web Analytics-Metriken, um die Grundlagenkategorien für eine Sammlung an In-Store Customer Analytics-Metriken zu entwickeln. Der zweite Teil ist eine strukturierte Literaturanalyse, welche auf die Kategorien des ersten Teils aufbaut und unter deren Berücksichtigung Literatur zu den Erfassungstechnologien systematisiert.

2.1 Web Analytics-Metriken

Während die Kundendatenerfassung im Ladenlokal noch ein Schattendasein führt, ist die Web Analyse bereits hochgradig organisiert und die vorhandenen Metriken sind standardisiert und strukturiert [TB03] [Gu13]. Die dafür verantwortliche Organisation, die Web Analytics Association (WAA) [We16], veröffentlicht auf ihrer Homepage eine Sammlung an strukturierten Web-Metriken und Definitionen, welche als weltweiter Standard gelten. Die WAA unterscheidet zwei Metrikarten, „Count“, als direkt gemessene Zahl (wie z.B. die Anzahl der Webseiten Besucher), und „Ratio“, als abgeleitete Metrik, die sich aus anderen Werten errechnen lässt (wie z.B. durchschnittliche Dauer pro Ladenbesuch). Die 22 vorgegebenen Metriken selbst werden in sechs Kategorien unterteilt, von denen nicht alle auf In-Store Customer Analytics-Metriken übertragbar sind.

1. Building Block	2. Visit Characterization	3. Visitor Characterization	4. Engagement	5. Conversion	6. Miscellaneous
Page	Entry Page	New Visitor	Page Exit Ratio	Conversion	Hit
Page View	Landing Page	Returning Visitor	Single Page Visits	Conversion Rate	Impressions
Visits	Exit Page	Repeat Visitor	Bounce Rate		
Unique Visitor	Visit Duration	Visitor Referrer	Page views per Visit		
Event	Referrer	Visits per Visitor			
	Session Referrer	Recency			
	Click-Through	Frequency			
	Click-Through-Rate				

Tabelle 1: Web Analytics-Kategorien und -Metriken [We16]

Die Kategorie 5 bezieht sich auf eine Verrechnung von Kundendaten und Transaktionsdaten und wird deshalb in der Betrachtung dieses Beitrages zurückgestellt. Die Metriken der Kategorie 6 sind in ihrer Definition nicht auf das Ladenlokal zu übertragen und fallen deshalb ebenfalls aus der Betrachtung. Überträgt man die verbleibenden vier Web Metrik-Kategorien, so lassen zwei In-Store Metrik-Kategorien ableiten:

1. Standort-Metriken der Kategorie „Visit Characterization“ und
2. Verhaltens-Metriken der Kategorie „Engagement“

Die Web Analytics Kategorien „Building Block“ und „Visitor Characterization“ zeigen darüber hinaus aber auf, dass die abgeleiteten Kategorien noch um eine Erkennungsgrad-

Dimension erweitert werden müssen, da sie sowohl individualisierte als auch identifizierte Standort- wie auch Verhaltensmetriken beinhalten. Für Metriken wie „New, Returning oder Repeat Visitor“ bedarf es entsprechend einer identifizierten Kundenerkennung, während Metriken wie „Visit“ schon mit einer individualisierten Erfassung erhoben werden können.

2.2 In-Store Customer Analytics-Metriken

Die folgende strukturierte Literaturanalyse mit dem Ziel der Identifikation von verfügbaren Technologien und Metriken zur Kundendatenerfassung im Ladenlokal, umfasst eine Suche von Journal- und Konferenzbeiträgen aus den Jahren 2000 bis 2016. Verwendet wurden jeweils einzeln die folgenden Suchwörter: Retail Analytics, Traffic Analytics, Operations Analytics, Behaviour Analytics, Customer Analytics, In-Store Analytics, Video-Analytics, In-Store Metrics, Shoppers Intelligence, Path Analysis, Traffic Analysis und Costumer Counting. Gesucht wurde in den Datenbanken von EbscoHost, IEEE Xplore, Springer Link und Google Scholar. Da Google Scholar sich mit Einträgen aus den anderen genannten und untersuchten Datenbanken überschneidet, wurden die Doppelungen vorab aussortiert. Des Weiteren wurden nur Journal- und Konferenzbeiträge berücksichtigt, welche einen direkten Zugang per PDF Download ermöglichten. Die Suche ergab einen Korpus von 284 Beiträgen. Der gesamte Literaturkorpus wurde durch eine Analyse der Titel und Abstracts auf 42 relevante Beiträge reduziert. Diese wurden vollständig betrachtet und es konnten abschließend 18 Beiträge ermittelt werden, welche die Basis für die hier durchgeführte Literaturanalyse bilden (Tabelle 3).

	EBSCOHost	IEEE Xplore	Springer Link	Google Scholar
Ergebnisse Total: 284	48	96	28	112
Nach Titel & Abstract: 42	12	14	7	9
Nach vollständiger Analyse: 18	1	6	4	7

Tabelle 2: Literaturauswahl

Die technologieneutral durchgeführte Suche führte ausschließlich zu technologiebezogenen Veröffentlichungen, von denen ein Großteil die Informationsgewinnung für den stationären Handel, wenn überhaupt, dann nur als Nebenprodukt aufführt. Dies deutet darauf hin, dass sich die Forschung bisher noch nicht eingehend mit dem Thema In-Store Customer Analytics auseinandergesetzt hat. Die Betrachtung der diskutierten Technologien in der Literatur lässt auf zwei Grunderfassungskategorien schließen: 1) direkt messende Technologien, welche den Kunden und seine Handlungen direkt erfassen, und 2) Proxy-Technologien, welche den Kunden mit Hilfe einer Instanz erfassen (z.B. über Einkaufswagen, Smartphones, etc.).

Die Kundenerfassung beider Kategorien (direkt und proxy) kann dabei in drei Graden erfolgen: 1) nicht individualisiert (Kunde kann nicht verfolgt und wiedererkannt werden), 2) individualisiert (Kunde kann verfolgt und wiedererkannt werden) und 3) identifiziert (Kunde kann verfolgt, wiedererkannt und eindeutig identifiziert werden).

Nr.	Author	Technologie	Alternativen	Metrik Kategorien	Kundenerkennung	In-Store Metrics
1.	Sorensen (2003)	RFID	RTLS	Multiple Locations	Proxy Individualized	Density, Speed of Purchasing, Quadrants, Speed of Shopping
2.	Hong et al. (2004)	WIFI	-	Multiple Locations	Proxy Individualized	-
3.	Li-Qun Xu (2007)	Video-Analysis (CCTV)	Optical Sensors	Multiple Locations, Action Event	Individualized	Crowd Density, Customer Counting
4.	Senior et al. (2007)	Video-Analysis (CCTV)	Infrared-Beams, Pressure Pads	Multiple Locations, Action Event	Individualized, Identified	Customer-Counting
5.	Bolliger (2008)	GSM, Bluetooth, WIFI	-	Multiple Locations	Proxy Individualized, Identified	-
6.	Yada (2009)	RFID	-	Multiple Locations	Proxy Individualized	Shopping Time, Staying Time in Sales Areas,
7.	Bourimi et al. (2011)	GSM, Bluetooth, WIFI	RFID, Indoor GPS, CCTV, Photo Sensors	Multiple Location	Proxy Individualized, Identified	-
8.	Blecker et al. (2011)	RFID	CCTV,	Multiple Locations, Action Event	Proxy Individualized	Visited Product Zones, Contact Instances, Physical Movement of Goods
9.	Rai et al. (2011)	Video-Analysis (CCTV)	WiFi, RFID	Multiple Locations	Proxy Individualized	Shopping Time, Staying Time in Sales Areas,
10.	Takai et al. (2012)	RFID	-	Multiple Locations	Proxy Individualized	Shopping Time, Staying Time in Sales Areas,
11.	Cai (2014)	WIFI	-	Multiple Locations	Proxy Individualized, Identified	-
12.	Conell et al. (2013)	Video-Analysis (CCTV)	-	Multiple Locations, Interaction Event	Individualized	People Counting, Conversion Rate, Buying Time and Staying Time, Cart Localization, Basket Size, Line Counting
13.	Rallapalli et al. (2014)	Smart Glasses	CCTV, WiFi	Multiple Locations, Interaction Event	Proxy Identified	Shopping Behavior: Walking, Dwelling, Gazing, Reaching out
14.	Yaeli et al. (2014)	WIFI	GPS, RFID, WiFi, Bluetooth	Multiple Locations	Proxy Identified	Store Zone, Store Visit, Zone Transition, Zone Visit Time, Store Visit, Unique / Repeat Customer, Store Exit Time, Store Enter Time, Time per Zone, Visitors to Store,
15.	Zeng et al. (2015)	WIFI	-	Multiple Locations	Proxy Identified	Walking Fast / Slow, Staying Time
16.	Deva et al. (2015)	WIFI	-	Multiple Locations	Proxy Identified	Returning Visitors, Visit Frequency, Visited Zones, Buying and Staying Time
17.	Pierdicca et al. (2015)	Beacon Technology	-	Multiple Locations	Proxy Individualized	Total Number of People, Avg. Visiting Time, People Passing by, Avg. Group Number, Interactions
18.	Liciotti et al. (2015)	Video – Analysis (CCTV)	-	Multiple Locations, Interaction Event	Individualized	Visitors, Visitors of a Zone, Interaction with Shelf / with Person / with Products, Duration of Interactions, Avg. Interaction Time

Tabelle 3: Literaturanalyse

Neben dem „Wie“ der Messung kann auch der Gegenstand der Messung, also das „Was“, als Gliederungskriterium (s.g. Metriken-Kategorie) für die zu vergleichenden Technologien herangezogen werden. Eine erste Gruppe von Technologien ist darauf ausgelegt, Standortdaten (Standort-Metriken) zu erfassen, was mit einzelnen (Single Location) oder mehreren (Multiple Locations) Messpunkten möglich ist. Während die „Single Location-Erfassung“ nur einem An-Aus Signal gleicht, sind mit der Erhebung von „Multiple Locations“ komplexere Auswertungen (z.B. Pfad-Analysen, Heatmaps) möglich. Die zweite Gruppe von Technologien befasst sich mit der Erhebung des physischen, über die reine Bewegung auf der Fläche hinausgehenden Kundenverhaltens (Verhaltens-Metriken). Auch diese Verhaltens erfassung lässt sich wiederum in zwei Unterkategorien gliedern: Die Messung von 1) individuellen Handlungen (Actions), wie z.B. Laufen, Warten, Betrachten, Greifen und 2) die Messung von Interaktionen (Interactions), wie z.B. von Gesprächen mit dem Personal (Interaktion mit Personal) oder das Heben von Produkten (Interaktion mit Produkten). Zur Auswertung und Interpretation der genannten Metrik-Kategorien bedarf es einer definierten Sammlung spezifischer Metriken, welche in Abschnitt 4 abgeleitet und diskutiert wird.

3 Technologien zur Erfassung physischer Kundenkontakte

Zur Erfassung physischer Kundenkontakte steht dem Handel mittlerweile eine Vielzahl an Technologien zur Verfügung. In der durchgeführten Literaturanalyse wurden acht Alternativen identifiziert, die Bandbreite reicht dabei von einfachen Lösungen wie Infrarot-Lichtschranken bis zu komplexen Lösungen wie Video-Systemen. In diesem Beitrag werden die Technologien ausschließlich autonom untersucht und mögliche Potenziale aus einer Vernetzung und die Gestaltung von Hybrid-Lösungen lediglich im Ausblick angesprochen. In der abgebildeten Tabelle 4 wird der jeweilige Leistungsumfang unter Berücksichtigung der Art der Messung (direkt / proxy), der erheblichen Metrik-Kategorien und des Kundenerkennungsgrades zusammenfassend dargestellt. Im weiteren Verlauf werden die aufgeführten Technologien kurz auf Vor- und Nachteile hin diskutiert.

		Metrik-Kategorien					
		Messung	Standort-Metriken		Verhaltens-Metriken		Kundenerkennung
			Single Location	Multiple Location	Action	Interaction	
Sensorik	Lichtschranken	Direkt	Ja	Nein	Nein	Nein	Nicht Individualisiert
	Druckplatten	Direkt	Ja	Nein	Nein	Nein	Nicht Individualisiert
	Optische Sensoren	Direkt	Ja	Ja	Nein	Nein	Individualisiert
Proxy-Technologien	RFID	Proxy	Ja	Ja	Ja	Nein	Identifiziert
	Beacon Technologie	Proxy	Ja	Ja	Ja	Nein	Identifiziert
	WIFI, GSM, Bluetooth	Proxy	Ja	Ja	Ja	Nein	Identifiziert
Tracking-systeme	Smart Glasses	Proxy	Ja	Ja	Ja	Ja	Identifiziert
	Video-Systeme	Direkt	Ja	Ja	Ja	Ja	Identifiziert

Tabelle 4: Überblick In-Store Customer Analytics Erfassungstechnologien

3.1 Rudimentäre Sensoren

Der Einsatz von Lichtschranken und Druckplatten zur Erfassung von Kundenkontaktdaten stellt die rudimentärste Form der Sensorik zur Kundenerfassung dar. Vorteile: Niedrige Kosten. Nachteile: Ausgelöst durch eine Unterbrechung des Lichtstrahls oder durch ein wahrgenommenes Gewicht geben diese Lösungen einen unreflektierten Zählwert aus, der durch seine Einfachheit einer hohen Ungenauigkeit unterliegt. Gruppen, Angestellte, Dienstleister, spielende Kinder im Eingangs- und Ausgangsbereich sowie Tiere werden beispielsweise ungefiltert mitgezählt. Diese Technologien sind zudem nicht in der Lage, Personen individualisiert zu verfolgen. Lichtschranken und Druckplatten eignen sich daher eher zur Trenderfassung, jedoch nicht zur konkreten Zählung von Kunden [Se07].

3.2 Optische Sensoren

Die Bandbreite der unter „optische Sensoren“ zusammengefassten Technologien reicht von Bewegungssensoren bis hin zu Wärmebildkameras. Vorteile: Die Technologien sind in höheren Entwicklungsstufen in der Lage, Personen im Ladenlokal individualisiert zu verfolgen und Analysen über deren Bewegungsabläufe zu generieren (z.B. Pfad-Analysen, Heatmaps). Da Sensoren-Systeme nicht in der Lage sind, Personen eindeutig zu identifizieren, bestehen dabei kaum datenschutzrechtliche Probleme. Nachteile: Die Gruppenerfassung ist für diese Sensoren oft noch eine Herausforderung, und es ist zu beachten, dass die entsprechenden Systeme autonom und unabhängig vom Kunden agieren und dieser somit keine Möglichkeit hat, sich der Messung zu entziehen [Xu07].

3.3 Proxy-Technologien

Die Gruppe der Proxy-Technologien umfasst Messungen über Wifi Netzwerke, RFID Chips, den Einsatz von Smart Glasses oder Smartphones mit Indoor GPS. Der jeweilige Leistungsumfang der einzelnen Technologien ist vielfältig [Bo09]. Vorteile: Über die Möglichkeit, Kunden eindeutig zu identifizieren, bieten sich durch die Vernetzungsmöglichkeiten z.B. mit Transaktions- und weiteren Kundendaten Möglichkeiten zur Personalisierung des Einkaufserlebnisses und zur Entwicklung digitaler Services, die auf ein erkanntes Kundenverhalten direkt reagieren können. Nachteile: Es muss berücksichtigt werden, dass das jeweilige Kundenverhalten nicht direkt, sondern lediglich indirekt über Proxys als Repräsentation des Kunden gemessen wird. Entsprechend kann es zu Messlücken kommen, wenn der Kunde den Erfassungsraum des Proxys verlässt, sich z.B. vom RFID-Einkaufswagen entfernt, sein Smartphone nicht dabei oder ausgeschaltet hat [So03] [Ca14] [Ya14].

3.4 Trackingsysteme

Video-Systeme stellen die komplexeste Gruppe an Technologien zur Erfassung von Kundenkontaktdaten im Ladenlokal dar. Getrieben durch die Entwicklungen in der Überwachungsindustrie [Xu07] sind Videosysteme heute in der Lage, Kunden zu zählen, ihre Pfade im Ladenlokal auszuwerten und ihre Handlungen (Actions) und Interaktionen (Interactions) zu erfassen. Vorteile: Sie können Gruppen analysieren und relevante von irrelevanten Messgegenständen unterscheiden (z.B. Menschen von Tieren). Gesichtserkennungssoftware, Gestik- und Mimikinterpretation führen zu einer zumindest potenziell erreichbaren, extrem hohen Datendichte, die sich immer stärker der Qualität einer direkten Beobachtung durch Personal angleicht [Li15]. Nachteil: Video-Systeme in der Kundenanalyse stehen unter datenschutzrechtlichen Gesichtspunkten in der Kritik [KPP12] [Co12].

4 In-Store Customer Analytics-Metriken

Um die bislang sehr technologiefokussierte Sicht auf die physische Kundenkontaktdatenerfassung mehr auf die für Händler bedeutende Informationsgewinnung durch Kundenkontaktdaten zu lenken, wird im Folgenden eine Sammlung an In-Store Customer Analytics-Metriken entwickelt. Eine Metrik lässt sich in vier Bausteine unterteilen: 1) die Kernmetrik, die Aufschluss über den Untersuchungsgegenstand gibt und somit den Hauptbestandteil darstellt. Die weiteren Bausteine werden als Präfix vor die Kernmetrik gesetzt, um diese weiter zu definieren. Da wären 2) das Individualisierungspräfix, welches Rückschlüsse auf identifizierte Kunden zulässt, 3) das Zählpräfix, welches die Art der Messung definiert (Anzahl, Häufigkeit, Zeitraum zur letzten Messung, Dauer) und dessen Einsatzmöglichkeit vom Metrik Typ abhängt (Count, Ratio oder Count / Ratio), sowie 4) das Verhältnispräfix, welches die gemessene Metrik in ein zeitliches Verhältnis zur Gesamterfassung setzt (Durschnitt pro Tag / Monat / Jahr) (siehe Tabelle 5). Eine Kernmetrik bedingt ein Zähl-Präfix, wohingegen Individualisierungs-Präfix und Verhältnis-Präfix optional sind. Im Folgenden werden zum Zwecke der Komplexitätsreduzierung nicht alle identifizierbaren In-Store Customer Analytics-Metriken aufgeführt, sondern nur die zugrundeliegenden Kernmetriken. Diese repräsentieren damit in Abhängigkeit des Metrik Typs jeweils weitere, ableitbare Metriken. Zur Ableitung kann man den in Tabelle 5 aufgeführten Metrik-Baukasten nutzen.

4*	3	2*	1
Verhältnispräfix	Zählpräfix (Metrik Typ)	Individual- präfix	Kernmetrik
Average / day	Number of (Count)	Unique	z.B. Visitor (Count)
Average / month	Frequency of (Count /Ratio)	New	
Average / year	Recency of (Count /Ratio)	Returning	
	Time per (Ratio)	Repeat	

Lese-Beispiel: Average (4) Number (3) of Unique (2) Visitors (1)

Tabelle 5: Metrik-Baukasten | * = optional

Die gesamte Sammlung umfasst 20 in der Literaturanalyse und den Web-Analytics Metriken identifizierte Kernmetriken, welche insgesamt 1248 Varianten der In-Store Customer Analytics Metriken repräsentieren. In Tabelle 6 sind die identifizierten Kernmetriken aufgeführt und den jeweiligen Metrik-Kategorien der verfügbaren Technologien und den Kundenerfassungskategorien zugeordnet. Im nächsten Kapitel wird eine Kundenerfassungs-Reifegrad-Matrix entwickelt, welche die bisher erarbeiteten Bausteine zusammenführt und einen Überblick über die verfügbaren Technologien und die von ihnen erfassbaren Kern-Metriken bietet.

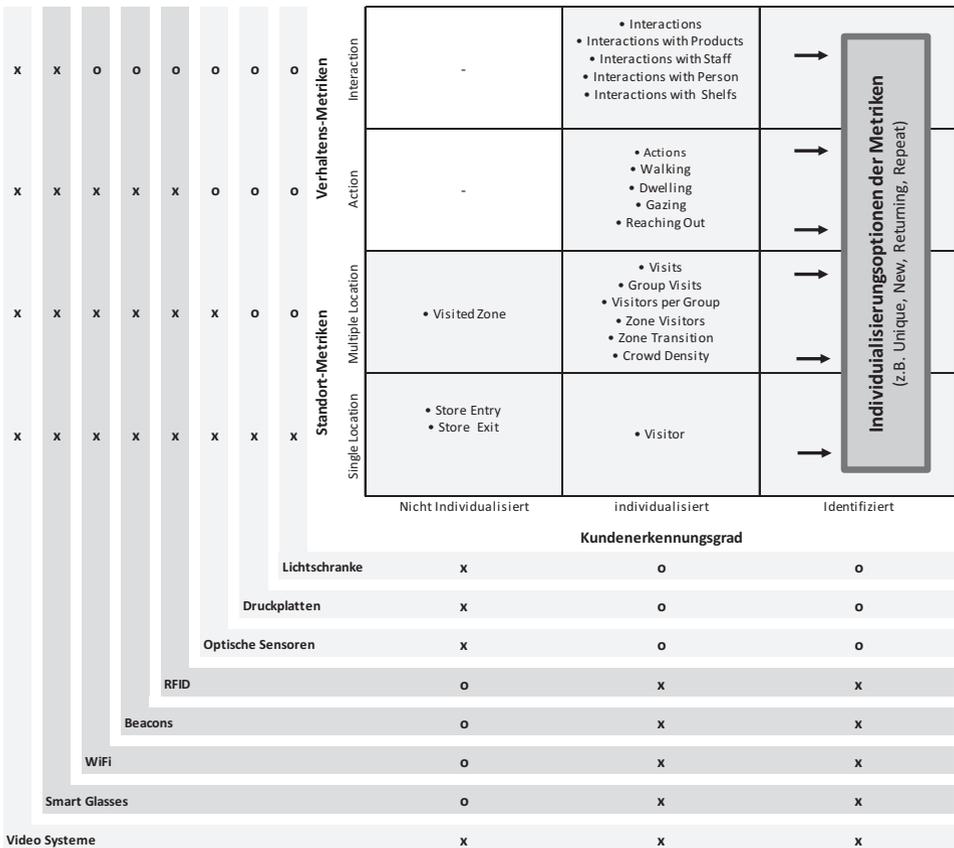
Nr.	Kernmetrik	Metriktyp	Single Location	Multiple Location	Action	Interaction	Kundenerfassung
1.	Store Entry	Count	x				Nicht Individualisiert
2.	Store Exit	Count	x				Nicht Individualisiert
3.	Visitor	Count	x				Individualisiert
4.	Visited Zone	Count / Ratio	o	x			Nicht Individualisiert
5.	Visits	Count / Ratio	o	x			Individualisiert
6.	Group Visits	Count / Ratio	o	x			Individualisiert
7.	Visitors per Group	Count	o	x			Individualisiert
8.	Zone Visitors	Count	o	x			Individualisiert
9.	Zone Transitions	Count	o	x			Individualisiert
10.	Crowd Density	Count	o	x			Individualisiert
11.	Actions	Count / Ratio	o	o	x		Individualisiert
12.	Walking	Count / Ratio	o	o	x		Individualisiert
13.	Dwelling	Count / Ratio	o	o	x		Individualisiert
14.	Gazing	Count / Ratio	o	o	x		Individualisiert
15.	Reaching out	Count / Ratio	o	o	x		Individualisiert
16.	Interactions	Count / Ratio	o	o	o	x	Individualisiert
17.	Interactions with Products	Count / Ratio	o	o	o	x	Individualisiert
18.	Interactions with Staff	Count / Ratio	o	o	o	x	Individualisiert
19.	Interaction with Person	Count / Ratio	o	o	o	x	Individualisiert
20.	Interactions with Shelves	Count / Ratio	o	o	o	x	Individualisiert

Tabelle 6: In-Store Customer Analytics Kernmetriken

5 Kundenerfassungs-Reifegrad-Matrix

Stationäre Händler stehen vor einer Vielzahl an Herausforderungen. Eine besteht darin, mit dem Online-Handel Schritt zu halten. Dem wachsenden Vorsprung in der Erfassung von Online-Kundenkontaktdaten für die Optimierung des Angebots und der Onlineshop-Oberflächen wird dabei gegenwärtig noch wenig Beachtung geschenkt. Die folgende Kundenerfassungs-Reifegrad-Matrix zeigt zu den im Laufe des Beitrags entwickelten Standort- und Verhaltens-Metriken (unterteilt in Single und Multiple Location, Actions und Interactions – von rudimentärer Standorterfassung bis zur komplexen Verhaltens-erfassung) und Kundenerkennungsgraden (Nicht individualisiert, individualisiert und identifiziert) den jeweiligen Leistungsumfang der Erfassungstechnologien auf und erweitert diese Betrachtung mit einer Zuordnung der identifizierten Kernmetriken zu den möglichen Erfassungsräumen. Die Kernmetriken werden in der Matrix in die Erfassungsräume mit dem niedrigsten Grad der möglichen Erfassung eingetragen und stehen damit den höheren Reifegraden – im Sinne einer Vererbung – auch zur Verfügung. So wird z.B. für die Messung eines „Visitors“ minimal eine individuelle Ein-Punkt-Standortmessung benötigt. Ein komplexeres System, das mehrere Standorte erfassen kann und in der Lage

ist Kunden zu identifizieren, ermöglicht auch die Erfassung der Metrik „Visitor“. In der folgenden Grafik sind die Proxy-Technologien mit einem dunkleren Grauton gekennzeichnet. Ein „x“ bedeutet, dass die Technologie den entsprechenden Leistungsumfang besitzt. Ein „o“ schließt den entsprechenden Leistungsumfang aus. Die weißen Flächen in der Matrix weisen darauf hin, dass die Erfassung von verhaltensbezogenen Metriken (Actions, Interactions) erst bei einer individualisierten oder identifizierenden Kundenerkennung möglich wird. Nicht individualisierte Messungen z.B. mit Lichtschranken oder Druckplatten können nur Standort-Metriken erfassen und sind nicht in der Lage, physische Aktionen (z.B. greifen) oder Interaktionen (z.B. Gespräche mit dem Personal) von Kunden zu erfassen und eindeutig zu identifizieren.



Grafik 1: Kundenerfassungs-Reifegrad-Matrix

Stellt man nun den Informationsgewinn anstatt der Technologien in den Fokus der Betrachtung, wird sichtbar, dass der Großteil der identifizierten Kernmetriken von Systemen mit einer individuellen Kundenerkennung geleistet werden kann. Zudem zeigt sich,

dass die Systeme mit einer identifizierenden Kundenerkennung bei der reinen Kundendatenerfassung nur geringfügige Vorteile bieten. Dies ändert sich allerdings, sobald eine Vernetzung der Systeme mit weiteren Daten(-banken) vorgenommen wird.

6 Implikationen

Die Kundendatenerfassung ist in der digitalen Welt längst etablierte Praxis. Stationären Händlern bietet die Kundendatenerfassung ein breites Spektrum an Weiterentwicklungsmöglichkeiten, wie z.B. einen Informationsgewinn in Bezug auf das transaktionsvorgelagerte Kundenverhalten. Diese Informationen könnten Händler nutzen, um das Angebot im Ladenlokal gezielter auf die Nachfrage auszurichten, um die Einrichtung und die Produktpräsentation den tatsächlichen erfassten Laufwegen und dem erkennbaren Kundenverhalten anzupassen, oder um den Einfluss von Marketingaktivitäten auf die Anzahl der Besucher im Ladenlokal zu überprüfen. Darüber hinaus würden Daten für eine verbesserte Personalplanung, z.B. in Bezug auf Kapazitäten und Einsatzbereiche verfügbar [CM15]. Ein weiterer interessanter Aspekt ist der im Online-Handel zu beobachtende Zusammenhang, dass der über eine automatisierte Erfassung permanent gewonnene Strom an Kundenkontaktdaten auch ein kontinuierliches Hinterfragen, Nachjustieren und Weiterentwickeln der Angebote und Services nach sich zieht. Und obwohl die rudimentärsten Datenerfassungstechnologien mit Ungenauigkeiten und Messschwierigkeiten zu kämpfen haben, stellen auch sie bereits einen erheblichen Informationsgewinn in Aussicht. Eine Lichtschranke in Verbindung mit Transaktionsdaten wäre z.B. dazu in der Lage, eine Conversion-Rate auf Trendbasis der Besuche im Ladenlokal zu erstellen. Große Probleme bereiten fast allen Technologien jedoch Gruppen von Kunden, die gleichzeitig ins Geschäft kommen. Auch die problematische Differenzierung zwischen Kunden und Personal, zwischen Kindern und Erwachsenen sowie zwischen Menschen und Tieren muss im Hinblick auf die Messergebnisse berücksichtigt werden. Trotzdem bietet sich Händlern die Möglichkeit, über eine skalierte Einführung der Erfassungstechnologien in die Analyse von Kundenkontaktdaten hineinzuwachsen. Der volle Analyseumfang ist bis heute nur mit hochentwickelten Video-Analyse-Systemen möglich. Für die größte Anzahl der In-Store Customer Analytics Metriken reichen aber schon Systeme, die eine individualisierte Kundenerkennung bieten, wie z.B. optische Sensoren-Systeme, welche unter datenschutzrechtlichen Aspekten weniger problematisch sind.

7 Fazit und Ausblick

Mit Hilfe einer strukturierten Literaturanalyse wurden die formulierten Forschungsfragen wie folgt beantwortet: 1) Es konnten acht verfügbare Technologien zur Erfassung von Kundenkontaktdaten identifiziert werden. Lichtschranken und Druckplatten lassen sich als eine ungenaue, dafür aber einfache Lösung charakterisieren. Optische Sensoren-Lösungen bieten einen hohen Informationsgewinn, aber keine Möglichkeit zur Identifi-

zierung und damit zur Personalisierung des Einkaufserlebnisses. Proxy-Lösungen wie RFID, WiFi, Beacon-Technology, Smartphone-Lösungen und Smart Glasses bieten einen großen Anwendungsraum, sind aber als indirekte Messmethoden mit Messlücken verbunden. Videosysteme bieten den größten Leistungsumfang, sind aber auch gleichzeitig besonders komplex und gehen auch unter datenschutzrechtlichen Gesichtspunkten mit erheblichen Herausforderungen einher. 2) Es konnten 20 In-Store Customer Analytics Kernmetriken (Tabelle 6) identifiziert werden, von denen mit Hilfe eines Metrik-Baukasten (Tabelle 5) insgesamt 1248 In-Store Customer Analytics-Metriken abgeleitet werden konnten. 3) Mit der Kundenerfassungs-Reifegrad-Matrix wurden schließlich die im Laufe des Beitrags entwickelten Bausteine zusammengeführt und in eine Übersicht zum Leistungsumfang der bestehenden Technologien und zu der jeweils realisierbaren Erfassung von In-Store Customer Kernmetriken überführt. Dieser Überblick soll Händler dabei unterstützen, Implementierungsentscheidungen technologieunabhängig und mit Fokus auf die avisierten Informationsgewinne treffen zu können.

In diesem Beitrag wurde der Fokus auf die autonome Untersuchung der Erfassungstechnologien gelegt. Potenziale, die sich durch die Vernetzung mit Transaktionsdaten oder durch Hybrid-Lösungen (Verbindung von Sensoren mit Proxy-Lösungen) ergeben, wurden ausgeklammert. Hybrid-Lösungen haben das Potenzial, die angesprochenen Messlücken der Proxy-Technologien zu überwinden, um unter gleichzeitiger Berücksichtigung des Datenschutzes personalisierte Angebote zu entwickeln. Darüber hinaus ist die Vernetzung der Kundenkontaktdaten mit Transaktions- und Kundendaten äußerst interessant in Bezug auf eine mögliche Anreicherung des stationären, physischen Einkaufsverhaltens mit digitalen Services. Die Kundenkontaktdatenerfassung ist der Grundstock, auf dem In-Store Empfehlungs- und Werbesysteme aufsetzen können. Sie bietet die Möglichkeit, neben Standortdaten (Location-based Services) auch Rückschlüsse aus dem Kundenverhalten zu ziehen. [Fz15] Stationäre Maßnahmen zur Kundenkontaktdatenanalyse sind also nicht nur unter dem Gesichtspunkt eines Anschlusshaltens mit dem Online-Handel zu betrachten, sondern sie stellen auch neue Geschäfts- und Service-Modelle in Aussicht, die vom reinen Onlinehandel schwer zu kopieren wären. Hierzu müssten jedoch zunächst die Qualität der erhobenen Daten verbessert und zum Beispiel die oben genannten Stördaten sauber gefiltert werden. Unter Berücksichtigung von Datenschutzbestimmungen müssten Schnittstellen für Hybrid-Lösungen sowie für eine Vernetzung der Messdaten mit Transaktions- und weiteren Kundendaten geschaffen werden. Es wäre zudem erforderlich, die im vorliegenden Beitrag identifizierten Metriken bzw. Metrik-Kategorien, um die Kategorie der Kontexterfassung zu erweitern. Die Erfassung von Kontextdaten erfordert eine integrierte Vernetzung aller zugänglichen Systeme, um über die Kombination von Verhaltens- und historischen Daten Informationen über den Kontext des Kundenverhaltens liefern zu können. Vor diesem Hintergrund soll in einem nächsten Schritt die Implementierung und Anwendung der entsprechenden Systeme in Praxisprojekten in den Vordergrund unserer Untersuchungen rücken, wobei der Fokus auf inhabergeführte stationäre Einzelhändler gelegt wird. Darauf aufbauend können in einem Folgeschritt die Potenziale einer Vernetzung mit Transaktions- und weiteren Kundendaten in einem Omni-Channel Retailing Ansatz in Augenschein genommen werden.

8 Literaturverzeichnis

- [BD95] Babin, B.J.; Darden, W.R.: Consumer self-regulation in a retail environment. *Journal of Retailing*, 71(1), S. 47-70, 1995.
- [Bi10] Bijmolt, T. H.; Leeﬂang, P. S.; Block, F.; Eisenbeiss, M.; Hardie, B.G.; Lemmens, A.; Saffert, P.: Analytics for customer engagement. *Journal of Service Research*, 13(3), S. 341-356, 2010.
- [BK12] Berman, S. J.; Kesterson-Townes, L.: Connecting with the digital customer of the future. *Strategy & Leadership*, 40(6), S. 29-35, 2012.
- [Bo08] Bolliger, P.: Redpin-adaptive, zero-configuration indoor localization through user collaboration. In *Proceedings of the first ACM international workshop on Mobile entity localization and tracking in GPS-less environments*, S. 55-60, ACM. 2008.
- [Bo09] Bolliger, P.; Partridge, K.; Chu, M.; Langheinrich, M.: Improving Location Fingerprinting through Motion Detection and Asynchronous Interval Labeling. In *Location and Context Awareness*, S. 37-51, 2009. Springer Berlin Heidelberg.
- [Bo11] Bourimi, M.; Mau, G.; Steinmann, S.; Klein, D.; Templin, S.; Kesdogan, D.; Schramm-Klein, H.: A Privacy-Respecting Indoor Localization Approach for Identifying Shopper Paths by Using End-Users Mobile Devices. In *Information Technology: New Generations (ITNG)*, Eighth International Conference, S. 139-144, IEEE. 2011.
- [BRT11] Blecker, T.; Rasch, C.; Teichert, T.: Prospects for PoS Market Research with RFID Technology: Examination of Consumers' In-Store Shopping Processes. In *European Retail Research*, S. 47-62, 2011 Gabler Verlag.
- [Ca14] Cai, D.: A retail application based on indoor location with grid estimations. In *Computer, Information and Telecommunication Systems (CITS)*, 2014 International Conference on, S. 1-4, IEEE. 2014.
- [Co12] Connell, J.; Fan, Q.; Gabbur, P.; Haas, N.; Pankanti, S.; Trinh, H.: Retail video analytics: an overview and survey. In *IS&T/SPIE Electronic Imaging*, S. 86630X-86630X, 2013. International Society for Optics and Photonics.
- [CM15] Chen, L.; Mersereau, A.J.: Analytics for Operational Visibility in the Retail Store: The Cases of Censored Demand and Inventory Record Inaccuracy. In *Retail Supply Chain Management*, S. 79-112, Springer US. 2015.
- [DFK02] Devaraj, S., Fan, M.; Kohli, R.: Antecedents of B2C Channel Satisfaction and Preference. *Information Systems Research*, 13(3), S. 316-333, 2002.
- [DML11] Davenport, T. H.; D'Ambo, D.; D'Ambo, L. D.; Lucker, J.: Know What Your Customers Want Before They Do. *Harvard Business review*, 89(12), S. 84-92, 2011.
- [DR15] Deva, B.; Ruppel, P.: Location Analytics as a Service: Providing Insights for Heterogeneous Spatiotemporal Data. In *Web Services (ICWS)*, 2015 IEEE International Conference on, S. 353-360, IEEE. 2015.
- [Fz15] Fang, Z.; et al.: Contemporaneous and delayed sales impact of location-based mobile promotions. *Information Systems Research* 26.3, S. 552-564, 2015.

- [GC05] Gagnon, J. L.; Chu, J.J.: Retail in 2010: a world of extremes. *Strategy & Leadership*, 33(5), S. 13-23, 2005.
- [Ge14] Germann, F.; Lilien, G. L.; Fiedler, L.; Kraus, M.: Do Retailers Benefit from Deploying Customer Analytics? *Journal of Retailing*, 90(4), S. 587-593, 2014.
- [Gr68] Granbois, D.H.: Improving the Study of Customer In-Store Behavior. *The Journal of Marketing*, S. 28-33, 1968.
- [Gu13] Gupta, R.; Mehta, K., Bhavsar, K.; Joshi, H.: Mobile web analytics. *International Journal of Advanced Research in Computer Science and Electronics Engineering (IJARCSEE)*, 2(3), S. 288, 2013.
- [HL04] Hong, J. I.; Landay, J. A.: An architecture for privacy-sensitive ubiquitous computing. In *Proceedings of the 2nd international conference on Mobile systems, applications, and services*, S. 177-189, ACM, 2004.
- [KPP12] Kenny, R.; Pierce, J.; Pye, G.: Ethical considerations and guidelines in web analytics and digital marketing: a retail case study. In *AiCE 2012: Proceedings of the 6th Australian Institute of Computer Ethics conference 2012*, S. 5-12, 2012. Australian Institute of Computer Ethics.
- [Li15] Liciotti, D.; Contigiani, M.; Frontoni, E.; Mancini, A.; Zingaretti, P.; Placidi, V.: Shopper Analytics: a Customer Activity Recognition System Using a Distributed RGB-D Camera Network. *Video Analytics for Audience Measurement Lecture Notes in Computer Science*, 2015 arXiv preprint arXiv:1508.06853.
- [NJ99] Naumann, E.; Jackson, D.W.: One more time: how do you satisfy customers? *Business Horizons*, 42(3), S. 71-76, 1999.
- [Pi15] Pierdicca, R., et al.: Low cost embedded system for increasing retail environment intelligence. *Multimedia & Expo Workshops (ICMEW)*, 2015 IEEE International Conference on. IEEE, 2015.
- [Ra14] Rallapalli, S.; Ganesan, A.; Chintalapudi, K.; Padmanabhan, V. N.; Qiu, L.: Enabling physical analytics in retail stores using smart glasses. In *Proceedings of the 20th annual international conference on Mobile computing and networking*, S. 115-126, 2014.
- [RJK11] Rai, H. G.; Jonna, K.; Krishna, P. R.: Video analytics solution for tracking customer locations in retail shopping malls. In *Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining*, S. 773-776, 2011. ACM.
- [Se07] Senior, A. W.; Brown, L.; Hampapur, A.; Shu, C. F.; Zhai, Y.; Feris, R. S.; Carlson, C.: Video analytics for Retail. *2007 IEEE Conference on Advanced Video and Signal Based Surveillance*, 2007.
- [So03] Sorensen, H.: The science of shopping. *Marketing Research*, 15(3), S. 30-35, 2003.
- [Su15] Suresh, S. (2015). Application of Retail Analytics Using Association Rule Mining In Data Mining Techniques With Respect To Retail Supermarket* A. Pappu Rajan.
- [TB03] Teltzrow, M.; Berendt, B.: Web-Usage-Based Success Metrics for Multi-Channel Businesses. In *Proc. of the WebKDD Workshop on Web Mining and Web Usage Analysis*, S. 17-27, 2003.

-
- [TY12] Takai, K.; Yada, K.: A framework for analysis of the effect of time on shopping behavior. *J Intell Inf Syst Journal of Intelligent Information Systems*, 2012.
- [We16] Web Analytics Association – Web Analytics Definitions, http://www.digitalanalyticsassociation.org/Files/PDF_standards/WebAnalyticsDefinitionsVol1.pdf, 29.04.2016.
- [Xu07] Xu, L. Q.: Issues in video analytics and surveillance systems: Research/prototyping vs. applications/user requirements. In *Advanced Video and Signal Based Surveillance, 2007. AVSS 2007. IEEE Conference on S. 10-14, 2007. IEEE*.
- [Ya09] Yada, K.: String analysis technique for shopping path in a supermarket. *J Intell Inf Syst Journal of Intelligent Information Systems*, 2009.
- [Ya14] Yaeli, A.; Bak, P.; Feigenblat, G.; Nadler, S.; Roitman, H.; Saadoun, G.; Sandbank, T.: Understanding customer behavior using indoor location analysis and visualization. *IBM Journal of Research and Development*, 58(5/6), S. 3-1, 2014.
- [ZPM15] Zeng, Y.; Pathak, P. H.; Mohapatra, P.: Analyzing Shopper's Behavior through WiFi Signals. In *Proceedings of the 2nd workshop on Workshop on Physical Analytics*, S. 13-18, ACM. 2015.