

Gebhardt, Marcel

**Article**

## Lead-Scoring bei B-to-B-Unternehmen – Eine Bestandsaufnahme

Marketing Review St.Gallen

**Provided in Cooperation with:**

Universität St. Gallen, Institut für Marketing und Customer Insight

*Suggested Citation:* Gebhardt, Marcel (2023) : Lead-Scoring bei B-to-B-Unternehmen – Eine Bestandsaufnahme, Marketing Review St.Gallen, ISSN 1865-7516, Thexis Verlag, St.Gallen, Vol. 40, Iss. 5, pp. 68-77

This Version is available at:

<https://hdl.handle.net/10419/301907>

**Standard-Nutzungsbedingungen:**

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

**Terms of use:**

*Documents in EconStor may be saved and copied for your personal and scholarly purposes.*

*You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.*

*If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.*

# Marketing Review

# St.Gallen

## Contemporary Branding



### Schwerpunkt

Das Erbe pflegen und ausbauen,  
ohne zu verstauben –  
Ein Interview mit Thomas P. Meier,  
Chief Executive Officer, Ricola

Markenführung, die Brücken baut –  
Ein Ansatz zur integrierten Markensteuerung

Return on Brand Investment –  
Taking a Data-driven Approach to Branding

Auf Taten müssen Worte folgen

Fünf Thesen zum Thema Branding – zugespitzt

Ädverteising –  
Dialekt in der geschriebenen Werbung

Social Media Influencers in Virtual Selling Tools

Gamification als Erfolgsfaktor moderner  
Markenführung – Das Beispiel SHEIN

### Spektrum

Lead-Scoring bei B-to-B-Unternehmen –  
Eine Bestandsaufnahme

# Lead-Scoring bei B-to-B- Unternehmen

Eine Bestandsaufnahme

Lead-Scoring umfasst die Bewertung und Priorisierung potenzieller Kaufinteressierter. Zu diesem Zweck wird versucht, die individuelle Kaufwahrscheinlichkeit vorherzusagen. Dieser Schritt stellt eine der wichtigsten und schwierigsten Aufgaben im Vertriebsprozess dar. Vor diesem Hintergrund befasst sich der Beitrag mit dem aktuellen Stand des Lead-Scorings in Wissenschaft und Praxis.

Marcel Gebhardt

Ein in der B-to-B-Praxis zentrales Steuerungsinstrument, um Marketing- und Vertriebsressourcen und -aktivitäten konsequent auf Verkaufschancen und -potenziale auszurichten, ist der Marketing & Sales Funnel. Er repräsentiert eine Darstellung der aufeinander aufbauenden Stufen eines Verkaufsprozesses von der Identifikation interessierter Unternehmen über deren Priorisierung bis hin zur Konvertierung in Verkaufsabschlüsse. So werden im Laufe eines Vertriebsprozesses aus einer Vielzahl an Interessenten weniger echte Leads, wovon nur eine Teilmenge zu zahlender Kundschaft wird (vgl. Gebhardt & Gebhardt, 2019). Daraus ergibt sich der trichterförmige Aufbau (vgl. Abbildung 1). Je enger der Trichter nach untenhin wird, desto konkreter werden die Beziehungen und desto wahrscheinlicher wird der Kaufabschluss (vgl. Gebhardt & Gebhardt, 2019). Das primäre Ziel besteht vor diesem Hintergrund darin, die «richtigen» Leads durch den Verkaufstrichter zur Vertriebsreife zu entwickeln.

Ein Grossteil der Leads wird in der Praxis im Bereich Marketingkommunikation generiert. Wenn ein Lead eine vordefinierte Qualität erreicht, wird er an den Vertrieb übergeben. Dieser Übergang stellt eine der zentralen Schnittstellen zwischen Marketing und Vertrieb dar (siehe Abbildung 1) und ist ein wesentlicher Erfolgsfaktor innerhalb des Funnels. Nur wenn die Zusammenarbeit zwischen Marketing und Vertrieb abgestimmt ist, funktioniert und es gelingt, «reife» Leads an den Vertrieb zu übergeben, kann der Vertrieb diese effektiv in Abschlüsse konvertieren. Zu diesem Zweck werden Leads im Marketing bewertet und priorisiert und ausschliesslich «hoch-priorisierte» Leads weitergeleitet (vgl. bspw. D'Haen et al., 2016; Dunkan & Elkan, 2015). Dieser Schritt wird auch als Lead-Scoring bezeichnet und umfasst die Analyse und Bewertung potenzieller Kundschaft auf Basis statischer Kunden- (z.B. soziodemografische Kriterien) und dynamischer Verhaltensattribute (z.B. Surfverhalten) mit dem Ziel, bereits in einer frühen Phase die Wahrscheinlichkeit eines späteren Kaufs zu schätzen, Leads zu priorisieren und eine fokussierte Vertriebsarbeit zu ermöglichen (vgl. Paschen et al., 2020). Lead-Scoring stellt im Kern also eine Prognoseaufgabe dar, in Form eines Klassifikationsproblems (vgl. z.B. Gabryel et al., 2018); z.B. Konvertierung eines Leads in eine Opportunity: ja/nein.

Verlässliche Prognosen von Kaufwahrscheinlichkeiten und belastbare Lead-Priorisierungen haben eine grosse praktische Relevanz. Dies lässt sich nachvollziehen, wenn man sich die negativen Auswirkungen vor Augen führt, die mit Fehlpriorisierungen einhergehen; dazu gehören (vgl. Nygård & Mezei, 2020; Paschen et al., 2020):

- Fehlallokation begrenzter und kostenintensiver Marketing- und Vertriebsressourcen
- Zeitverschwendung bei der Evaluation und Ansprache «unreifer» Leads im Vertrieb



**Marcel Gebhardt**  
 Professor für ABWL,  
 insb. B-to-B Marketing & Technical Sales,  
 Hochschule Mannheim,  
 Fakultät für Wirtschaftsingenieurwesen  
[m.gebhardt@hs-mannheim.de](mailto:m.gebhardt@hs-mannheim.de)

- Verlust von Verkaufspotenzialen
- Fehlplanung und -steuerung im Vertrieb

Monat (2011) konstatiert hierzu:

«Sales leads are the lifeblood of industrial companies, yet determining which leads are likely to convert to bookings is often based upon guesswork or intuition. This results in a waste of resources, inaccurate sales forecasts, and potential loss of sales.»

(Monat, 2011, S. 192)

Lead-Scoring ist eine der wichtigsten und gleichzeitig eine der schwierigsten Aufgaben im gesamten Verkaufsprozess (vgl. Trailer, 2006; Moncrief & Marshall, 2005). Vor diesem Hintergrund befasst sich der Beitrag mit aktuellen Ansätzen, Methoden und Entwicklungen im Bereich des Lead-Scorings. Ziel ist es, den aktuellen Stand in Wissenschaft und Praxis zu beleuchten sowie einen Ausblick zu entwickeln, indem Anforderungen an Lead-Scoring-Modelle abgeleitet werden.

## Konzeptionelle Grundlagen: Typischer Aufbau des Marketing & Sales Funnels

- *Suspects* umfassen alle noch nicht qualifizierten Kontakte, bei denen vermutet wird, dass sie als Käufer infrage kommen.

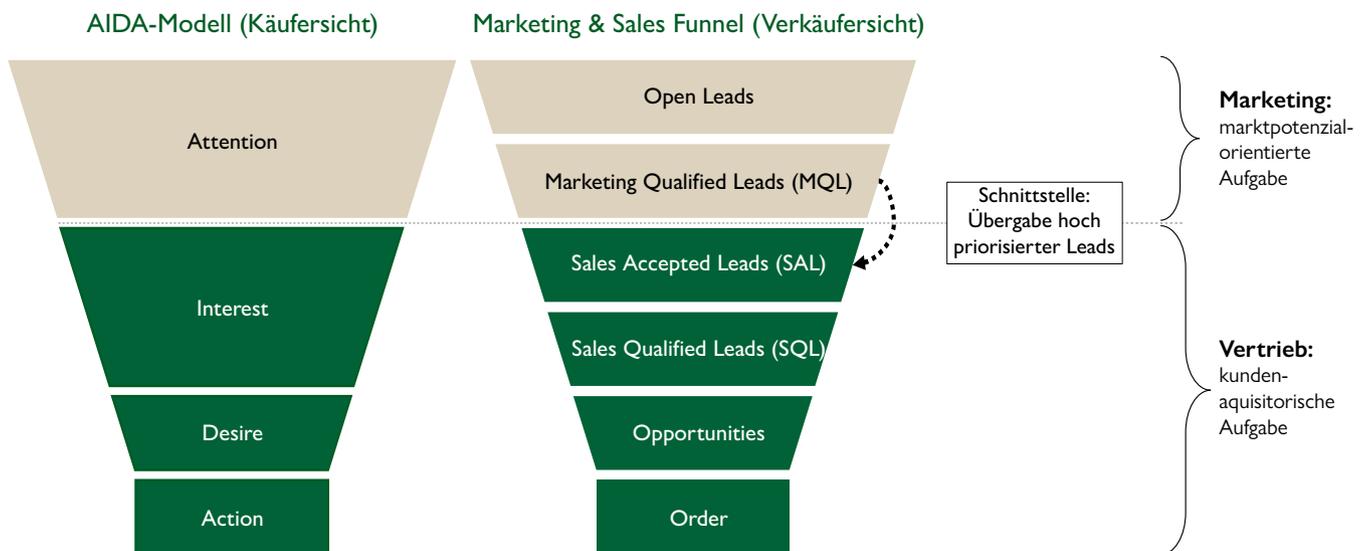
### Zusammenfassung

- 1 Verlässliche Prognosen von Kaufwahrscheinlichkeiten und belastbare Lead-Priorisierungen haben eine grosse praktische Relevanz.
- 2 Lead-Priorisierung wird in vielen Unternehmen nach wie vor auf Basis von Bauchentscheidungen oder mithilfe einfacher Nutzwertanalysen durchgeführt.
- 3 In der Wissenschaft wurden viele Fragen aus dem Bereich Lead-Scoring noch nicht ausreichend untersucht.

Es handelt sich um «Verdächtige», die grundsätzlich interessant sind (vgl. Gebhardt & Gebhardt, 2019).

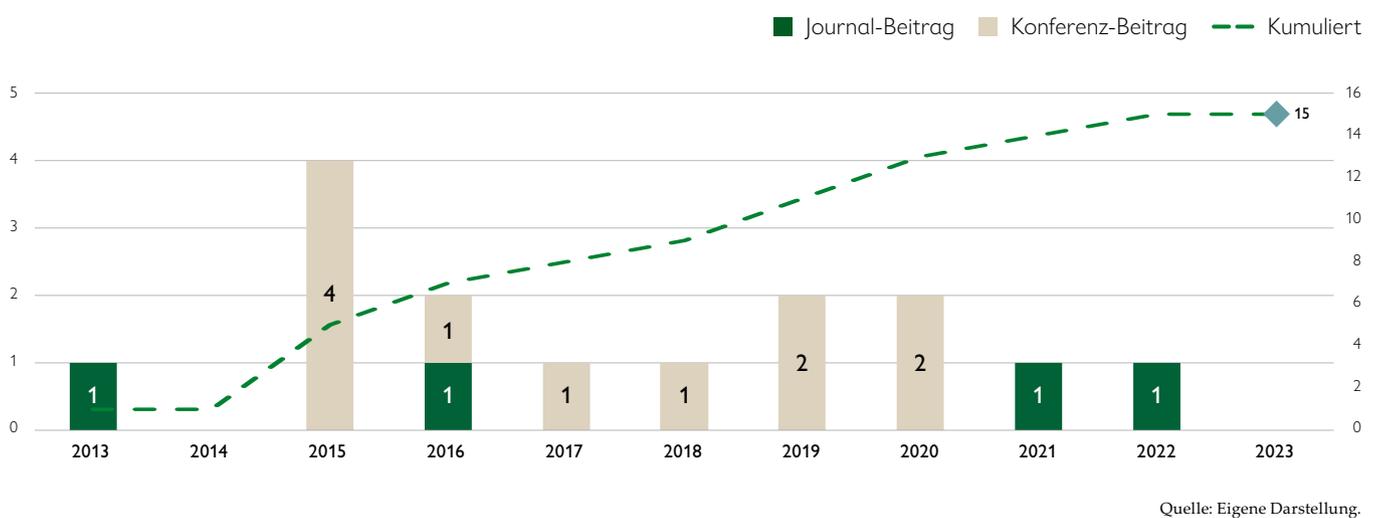
- *Open Leads* umfassen die hinsichtlich Zielkundenkonsistenz qualifizierten Kontakte. Zur Beurteilung dienen Merkmale wie Grösse, Branche, Tätigkeit. Darüber hinaus ist der Kundenstatus von Bedeutung. Anhand der Kriterien lassen sich die potenziellen Käufer konkretisieren. Open Leads sind so dem Zielkundenprofil entsprechende «Verkaufsspuren». Sie haben noch nicht zwingend einen Bedarf ausgedrückt.
- *Marketing Qualified Leads (MQL)* sind weiter qualifizierte und nach Kaufwahrscheinlichkeiten priorisierte Interessierte. Zu diesem Zweck erfolgt eine zentrale Bewertung. Dieser Schritt wird als Lead-Scoring bezeichnet (vgl. Duncan & Elkan, 2015; Dordevic, 2019). Hierzu werden weitere Merkmale herangezogen (z.B. Finanzindikatoren). Zudem werden die Interaktionen bewertet. Alle Touchpoints fliessen in die Bewertung ein. Auf Basis der Kundenmerkmale und der Art/Anzahl der Touchpoints lassen sich Lead-Scores ermitteln. Je höher der Score, desto höher die Kaufwahrscheinlichkeit. Leads, die eine gewisse Kaufwahrscheinlichkeit erreichen, werden an den Vertrieb übergeben (vgl. z.B. Mortensen et al., 2019). Alle weiteren werden im Rahmen von Lead-Nurturing-Kampagnen systematisch weiter mit Informationen versorgt und bearbeitet, bis sie die für die Übergabe erforderliche Reife erreicht haben (vgl. Monat, 2011).
- *Sales Accepted Leads (SAL)*: Diese Stufe stellt die Schnittstelle zwischen Marketing und Vertrieb dar. Es ist wichtig, dass ein Verständnis darüber existiert, wann ein Lead «reif» ist. Die Einhaltung der Kriterien wird vertriebsseitig überprüft. Bei Verifizierung des Potenzials wird der Lead an den Aussendienst weitergegeben.

Abb. 1: AIDA-Modell und Marketing & Sales Funnel



Quelle: Eigene Darstellung.

Abb. 2: Entwicklung der wissenschaftlichen Publikationen zu Lead-Scoring-Methoden und -Prozessen von 2010 bis 2023



- *Sales Qualified Leads (SQL)*: Nach der Übergabe der Leads an den Aussendienst erfolgt die Kontaktaufnahme. Ein Lead erreicht den Reifegrad eines SQL, wenn der Vertrieb den Bedarf, das Interesse sowie den groben Investitionszeitraum validiert hat (vgl. Nygård & Mezei, 2020).
- *Opportunities* sind unmittelbar bevorstehende Verkaufsmöglichkeiten. Zur Beurteilung, ob ein Lead den Reifegrad einer Opportunity erreicht (hat), werden in der Praxis häufig die weitverbreiteten BANT-Kriterien (Budget, Authority, Need, Time) herangezogen. Sind die Kriterien erfüllt, so liegt eine konkrete Verkaufschance vor.
- *Order*: Konvertierung der Opportunities in Kaufabschlüsse im Rahmen der Auswahlprozesse und Verhandlungen.

Entgegen einiger Auffassungen in der Literatur (vgl. z.B. D'Haen & Van den Poel, 2013; Eitle & Buxmann, 2019) eignet sich der Marketing & Sales Funnel nicht nur für die Akquisition von Neukundschaft, sondern genauso für die systematische Bearbeitung und Nachverfolgung von Bestandskundschaft (bspw. im Rahmen von Verkaufskampagnen).

## B-to-B-Lead-Scoring in der Wissenschaft

Die Erhebung des Stands der Forschung erfolgte auf Grundlage einer umfassenden Literaturrecherche. Hierfür wurde eine sys-

tematische Recherche der einschlägigen Literatur mithilfe der Literaturdatenbanken Google Scholar sowie EBSCOhost unter Verwendung der folgenden Suchbegriffe durchgeführt: lead scoring, lead prioritization, lead prediction, sales funnel prediction, predictive prospecting, sales propensity. Es wurden nur Studien ausgewählt, die die Vorhersage von Einzelfallkaufwahrscheinlichkeiten zum Gegenstand haben und einen B-to-B-Kontext betrachten. Abbildung 2 fasst die Entwicklung der Anzahl der Journal- und Konferenzbeiträge von 2010 bis Januar 2023 zusammen.

Wie aus Abbildung 2 hervorgeht, existieren auf den ersten Blick verhältnismässig wenig wissenschaftliche Beiträge (insbesondere peer-reviewed), die sich explizit mit Modellen, Methoden und Prozessen rund um das Thema Lead-Scoring befassen. Mortensen et al. (2019) hält hierzu fest:

«The academic work that does exist either is related to forecasting aggregate sales instead of scoring opportunity level propensity, or is based on custom algorithms that fall outside the standard tools used by data scientists in industry.»

(Mortensen et al., 2019, S. 1)

**Tabelle 1: Literaturüberblick zum Forschungsfeld Lead-Scoring**

Autorenschaft	Jahr	Forschungsziele	Datenbasis	Methoden/Algorithmen
D'Haen und Van den Poel	2013	Quantitatives 3-Phasen-Modell zum Lead-Scoring bei Neukunden	<ul style="list-style-type: none"> <li>• Kundendaten eines Telekommunikationsdienstleisters</li> <li>• Suspect-Daten aus externer Datenbank</li> </ul>	<ul style="list-style-type: none"> <li>• Phase 1 (Ähnlichkeitssuche zwischen Suspects und Bestandskunden): Look-Alike-Modell</li> <li>• Phase 2 (Modelltraining): Log. Regression, Entscheidungsbaum, Neuronales Netz</li> <li>• Phase 3: Gewichtung der Ergebnisse aus 1 und 2</li> </ul>
Bohanec et al.	2015	Machine-Learning-basiertes Lead-Scoring	Keine konkrete Angabe	Prognosewettbewerb bestehend aus: <ul style="list-style-type: none"> <li>• Naive Bayes Klassifikator</li> <li>• Entscheidungsbaum</li> <li>• Random Forest Klassifikator</li> </ul>
Duncan und Elkan	2015	Machine-Learning-basiertes Lead-Scoring	<ul style="list-style-type: none"> <li>• Fallstudie 1: Funneldaten eines SaaS-Anbieters</li> <li>• Fallstudie 2: Funneldaten eines Softwareanbieters</li> </ul>	Gradient Boosting Klassifikator
Yan et al.	2015a	Machine-Learning-basiertes Lead-Scoring	Funneldaten eines <i>Fortune 500</i> Technologieunternehmens	Log. Regression
Yan. et al.	2015b	Machine-Learning-basiertes Lead-Scoring	Funneldaten eines <i>Fortune 500</i> Technologieunternehmens	Hawkes-Prozesse und -Lernalgorithmen
D'Haen et al.	2016	Quantitatives Entscheidungssystem zum Lead-Scoring bei Neukunden	<ul style="list-style-type: none"> <li>• Kundendaten eines Energieversorgers</li> <li>• Web-Crawling zur Datenanreicherung</li> </ul>	Log. Regression
Sung et al.	2016	Machine-Learning-basiertes Lead-Scoring	Cloud Platform Website	Prognosewettbewerb bestehend aus: <ul style="list-style-type: none"> <li>• Log. Regression</li> <li>• Naive Bayes Klassifikator</li> <li>• Entscheidungsbaum</li> <li>• Random Forest Klassifikator</li> <li>• Gradient Boosting Klassifikator</li> <li>• Adaptive Boosting Klassifikator</li> <li>• K-Nearest Neighbor Klassifikator</li> </ul>
Benhaddou und Leray	2017	Datenbasierte Kriterienselektion für Lead-Scoring-Modelle	Kundendaten eines Softwareunternehmens	Bayes'sches Netz
Gabryel et al.	2018	Text-Mining-basiertes Lead-Scoring-System	Lead-Daten einer polnischen Bank	«Bag of Words»-Algorithmus
Mortensen et al.	2019	Machine-Learning-basiertes Lead-Scoring	Funneldaten eines Papierverarbeitungs- und Verpackungsunternehmens	Prognosewettbewerb bestehend aus: <ul style="list-style-type: none"> <li>• Log. Regression</li> <li>• Entscheidungsbaum</li> <li>• Random Forest Klassifikator</li> <li>• Gradient Boosting Klassifikator</li> </ul>
Eitle und Buxmann	2019	Machine-Learning-basiertes Lead-Scoring	Funneldaten eines <i>Fortune 500</i> Softwareunternehmens	Prognosewettbewerb bestehend aus: <ul style="list-style-type: none"> <li>• Random Forest Klassifikator</li> <li>• Support Vector Machine</li> <li>• eXtreme Gradient Boosting Klassifikator</li> <li>• Gradient Boosting Klassifikator</li> </ul>
Nygård und Mezei	2020	Machine-Learning-basiertes Lead-Scoring	Keine konkrete Angabe	Prognosewettbewerb bestehend aus: <ul style="list-style-type: none"> <li>• Log. Regression</li> <li>• Entscheidungsbaum</li> <li>• Random Forest Klassifikator</li> <li>• Neuronales Netz</li> </ul>
Thiess et al.	2020	Gestaltungsgrundsätze für erklärbare Modelle zur Vorhersage von Kaufwahrscheinlichkeiten	Fallstudie mit MAN Energy Solutions	Konzeptionelle Arbeit
Marvasti et al.	2021	Analyse des Online-Surfverhaltens von Leads zur Vorhersage der zugehörigen Funnelstufe	<ul style="list-style-type: none"> <li>• Simulationsstudie</li> <li>• Fallstudie (keine konkreten Angaben)</li> </ul>	Hidden Markov Model
Rohaan et al.	2022	Machine-Learning-basiertes Lead-Scoring	Funneldaten eines Aftersales-Service-Anbieters	Prognosewettbewerb bestehend aus: <ul style="list-style-type: none"> <li>• Log. Regression</li> <li>• Gradient Boosting Klassifikator</li> <li>• Random Forest Klassifikator</li> </ul>

Quelle: Eigene Darstellung.

Erst seit dem Jahr 2015 werden regelmässig einschlägige Publikationen veröffentlicht – wenngleich auch nur vereinzelt. Vor dem Hintergrund der praktischen Relevanz verlässlicher Lead-Priorisierungen ist dies überraschend; umso mehr, da viele Unternehmen heutzutage vor einem neuen Potenzial in Form einer neuen Dimension der Verfügbarkeit strukturierter und unstrukturierter Daten stehen und vielversprechende Datenanalysekonzepte existieren. Sung et al. (2016), Syam und Sharma (2018) genauso wie Paschen, Wilson und Ferreira (2020) stellen vor diesem Hintergrund explizit die Bedeutung von Machine-Learning und umfassender Kunden- und Vertriebsdatennutzung zur evidenzbasierten Lead-Priorisierung heraus, ohne dabei jedoch methodischen Erkenntnisfortschritt in den Mittelpunkt der Betrachtung zu stellen.

Ein genauerer Blick in die Literatur zeigt, dass die einschlägigen Studien, die sich explizit mit der Entwicklung von Modellen und Methoden zur Priorisierung von Leads auf Einzelkunden-Ebene befassen, durchaus performante quantitative Ansätze entwickelt haben und deren spezifische Einsatzmöglichkeiten aufzeigen. Da der Grossteil dieser Studien wissenschaftliche Konferenzbeiträge sind (vgl. Abbildung 2), lässt sich die Vermutung anstellen, dass die Forschung in dieser Nische noch relativ am Anfang steht.

Relevante Beiträge im Forschungsfeld Lead-Scoring sind in Tabelle 1 zusammengefasst (chronologisch sortiert).

Die vergleichsweise junge Lead-Scoring-Literatur zeigt, dass versucht wird, auf Grundlage von Einzelfallstudien das Potenzial von Machine-Learning-Algorithmen für die Vorhersage von Kaufwahrscheinlichkeiten auf Einzelfallkundenebene nutzbar zu machen. Gemeinsames Ziel der Studien ist es, auf Basis geeigneter Prädiktoren möglichst gute Vorhersagen für Kauf- bzw. Konversionswahrscheinlichkeiten zu generieren. Die Prädiktoren, die dabei herangezogen werden, beziehen sich auf demografische (statische) sowie verhaltensbezogene (dynamische) Kundenattribute (vgl. z.B. Rohaan et al., 2022; Nygård & Mezei, 2020; D’Haen et al. 2016; Benhaddou & Leray, 2017; Monat, 2011). Zu den demografischen Merkmalen zählen beispielsweise Branche, Grösse, Sitz, Finanzkennzahlen, etc.; die verhaltensbezogenen umfassen beispielsweise Kaufhistorie (Häufigkeit, Wert, Kategorie), Kundenstatus, Art und Anzahl Interaktionen (z.B. Webinarteilnahme, Messebesuch, etc.).

Als Datenbasis dienen den Studien Kunden-/Funnel Daten von Unternehmen aus unterschiedlichen Branchen. Zwar kommen zur Entwicklung der Vorhersagen überwiegend die gängigen Klassifikationsalgorithmen wie Logistische Regression, Entscheidungsbaum-, Random Forest Tree-, Naive Bayes-, Gradient Boosting- oder Support Vector Machine-Klassifikatoren zum Einsatz (vgl. Tabelle 1). Ein Vergleich der Studien sowie der

Qualität der entwickelten Ansätze ist dennoch aufgrund der unterschiedlichen Settings nicht ohne Weiteres möglich. So unterscheiden sich die untersuchten Einzelunternehmen erstens im Hinblick auf Grösse, Branche, Unternehmenssitz sowie Vertriebs- und Kundenstruktur. Zweitens unterscheiden sich Ziele und Reichweite der Prognosemodelle: Sie reichen von einstufigen (Lead-to-Opportunity- oder Lead-to-Order-Wahrscheinlichkeiten) (z.B. D’Haen et al., 2013; Yan et al., 2015a; Yan et al., 2015b; D’Haen et al., 2016; Benhaddou & Leray, 2017; Mortensen et al., 2019) bis hin zu mehrstufigen Vorhersagen, die mehrere Ebenen im Funnel betreffen (Lead-to-Opportunity-to-Order-Wahrscheinlichkeiten) (z.B. Duncan & Elkan, 2015; Eitle & Buxmann, 2019; Marvasti et al., 2021). Drittens wird eine Vergleichbarkeit erschwert durch die unterschiedlichen Vorgehensweisen, Prozesse und das notwendige spezifische Kontextwissen (z.B. Branche, Kunden) zur Entwicklung der Prognosemodelle.

Aus der Literaturanalyse gehen darüber hinaus die folgenden zentralen Erkenntnisse hervor:

- In vielen der Studien wird die Güte unterschiedlicher Modelle und Algorithmen in Form empirischer Prognosewettbewerbe verglichen. Dabei werden deskriptive Evaluationen der Ergebnisse vorgenommen, aus denen jedoch nicht hervorgeht, ob einzelne Ansätze anderen systematisch überlegen sind (signifikante Unterschiede zwischen den Ergebnissen?).
- Die bisher entwickelten Lead-Scoring-Methoden behandeln die Prognoseerstellung überwiegend im Sinne eines «Black-box-Vorgangs». So kann von aussen nicht ohne Weiteres nachvollzogen und beurteilt werden, wie genau die Ergebnisse zustande kommen und aufgrund welcher Faktoren

### Kernthesen

- 1 Lead-Scoring ist eine der wichtigsten und gleichzeitig eine der schwierigsten Aufgaben im gesamten Verkaufsprozess.
- 2 Eine flächendeckende Implementierung Machine-Learning-basierter Lead-Scoring-Methoden scheitert bis dato an fehlendem «Können» und/oder mangelndem «Wollen».
- 3 Der Erfolg neuer Lead-Scoring-Methoden wird entscheidend von der Akzeptanz der damit arbeitenden Mitarbeitenden determiniert.

Leads priorisiert werden. In Thies et al. (2020) und Bohanec et al. (2017) finden sich zwar erste Empfehlungen und Gestaltungsprinzipien zur Ableitung von Explainable Artificial Intelligence (XAI)-Modellen, die erklärbare Vorhersagen treffen sollen. Diese sind jedoch eher konzeptioneller Natur. Insbesondere hier besteht noch weiterer Forschungsbedarf.

Ergebnissen von Lead-Scoring direkt befasst und entsprechend aussagefähig sind. Die zentralen Ergebnisse sind in Abbildung 3 dargestellt. Die Ergebnisse stellen aufgrund des kleinen Stichprobenumfangs nur erste Vermutungen dar. Es sind weitere empirische Studien erforderlich, die die Beobachtungen konkretisieren und aus denen sich generalisierbare Aussagen ableiten lassen. Aus diesem Grund werden die hier angestellten Argumentationen zunächst verstärkt mit Erkenntnissen aus der Literatur untermauert.

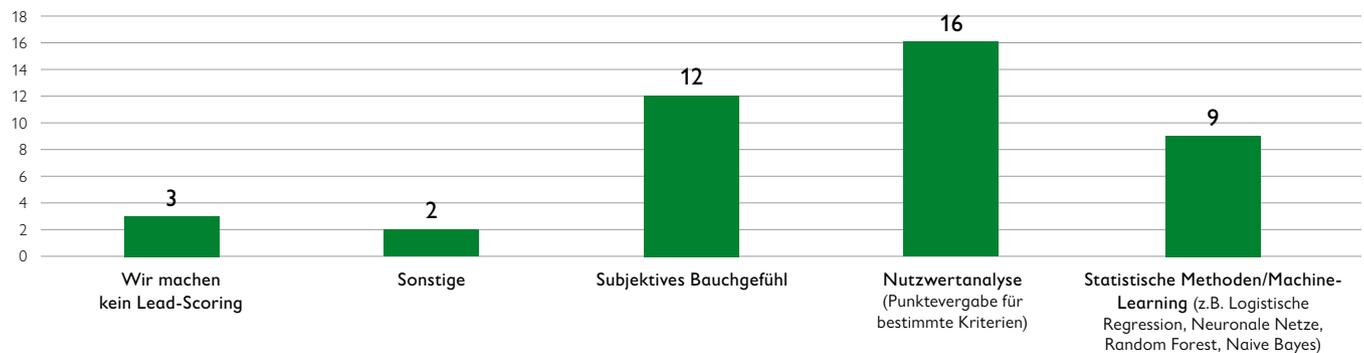
## Lead-Scoring in der B-to-B-Praxis

Um ein Lead-Scoring der B-to-B-Praxis zu erhalten, wurde eine Online-Kurzumfrage zu verwendeten Lead-Scoring-Methoden unter Vertriebsexperten deutscher Unternehmen aus unterschiedlichen Industriegüterbranchen durchgeführt (N = 42) (Stichprobenverteilung über Branchen: 46% Maschinen- und Anlagenbau, 21% Metallverarbeitung, 12% Automotive, 9% Elektrotechnik, 6% HVAC, 3% Chemische Industrie, 3% Software). Dopplungen wurden ausgeschlossen. Es wurden zudem ausschliesslich Antworten von Expertinnen und Experten berücksichtigt, die selbst mit der Durchführung oder den

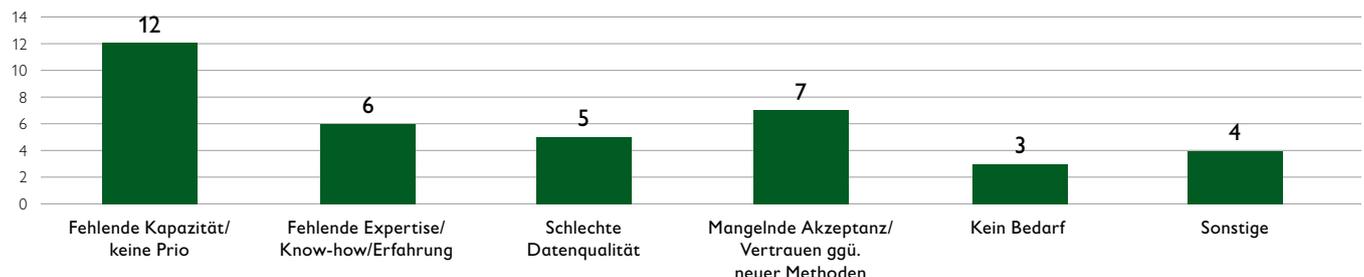
Die Umfrageergebnisse verdeutlichen, dass Lead-Priorisierungen in vielen Unternehmen nach wie vor Bauchentscheidungen sind und/oder mithilfe einfacher Nutzwertanalysen und Annahmen durchgeführt werden. Vielversprechende Ansätze aus dem Bereich moderner Datenanalysekonzepte/Machine-Learning kommen Stand heute nicht flächendeckend zum Einsatz. Dies gilt vermutlich über alle B-to-B-Branchen und Unternehmensgrößen hinweg. Diese Beobachtung deckt sich auch mit den bisherigen Erkenntnissen aus der Literatur (siehe z.B. Nygård & Mezei, 2020; Eitle & Buxmann, 2019; Duncan & Elkan, 2015).

Abb. 3: Umfrageergebnisse

Verwendete Lead-Scoring-Methoden  
(Anz. Nennungen)



Mögliche Gründe, dass Machine-Learning für Lead-Scoring bisher nicht zum Einsatz kommt  
(Anz. Nennungen; mehrere Aussagen je Teilnehmerin und Teilnehmer möglich)



Quelle: Eigene Darstellung.

«Most sales managers believe that they understand the key observable lead characteristics (e.g. whether or not there is an approved project, whether or not the project is funded, presence or absence of competition, urgency) that determine whether or not a lead will convert; however, few sales managers validate their assumptions or use quantitative tools to determine conversion probability of individual or aggregate leads.»

(Monat, 2011, S. 178)

Die verwendeten pragmatischen Praxisansätze führen dabei häufig zu verzerrten Ergebnissen (vgl. Duncan & Elkan, 2015). Diese lassen sich zurückführen auf eine zumeist willkürliche Auswahl, Wertung und Gewichtung der Lead-Kriterien. Gleiches gilt für die Festlegung der Wirkbeziehungen zwischen den Prädiktoren. Insbesondere nicht-lineare Effekte bleiben zudem unberücksichtigt. Hierzu ein einfaches Beispiel (vgl. dazu Duncan & Elkan, 2015): Ein potenzieller Kunde, der viele Webinare besucht, wird mit einer einfachen Nutzwertanalyse hoch priorisiert, da er für jede Webinarer Teilnahme  $x$  Punkte «sammelt». Es ist jedoch anzunehmen, dass die Grenzkaufwahrscheinlichkeit ab einer bestimmten Anzahl an Webinarer Teilnahmen abnehmend ist – eine weitere Teilnahme geht dann nicht mit einer Steigerung der implizierten Kaufwahrscheinlichkeit einher. Vielmehr ist von einer umgekehrten Wirkrichtung in Form einer umgekehrten U-Kurve auszugehen, sodass eine häufige Teilnahme eher ein negatives Signal darstellt (z.B. Teilnahme von Wettbewerbern). Dieses Beispiel zeigt, dass die restriktiven Annahmen und limitierten Analysemöglichkeiten einfacher Nutzwertanalysen schnell zu Verzerrungen führen können.

Die Umfrageergebnisse lassen zudem erste Gründe vermuten, weshalb moderne Lead-Scoring-Algorithmen bisher nicht zum Einsatz kommen. Die angegebenen Gründe können dabei im Wesentlichen auf fehlendes «Können» und mangelndes «Wollen» zurückgeführt werden. Fehlendes «Können» meint fehlende Kapazität und/oder fehlendes Know-how und Erfahrung, um geeignete Ansätze zu entwickeln. Mangelndes «Wollen» bezieht sich auf eine in der Praxis häufig vorherrschende Algorithmus-Aversion. Unter Algorithmus-Aversion wird dabei die Ablehnung von nachweislich überlegenen Algorithmen durch Menschen verstanden, nachdem sie festgestellt

## Handlungsempfehlungen

- 1 Befassen Sie sich mit den Potenzialen datenbasierter Lead-Scoring-Modelle; prüfen und vergleichen Sie die Performanz aller relevanten Klassifikationsalgorithmen.
- 2 Befassen Sie sich mit der Entwicklung erklärbarer Prognosemodelle (XAI).
- 3 Integrieren Sie alle statischen und dynamischen Kunden- und Verhaltensattribute, die für die Vorhersage relevant sein können; Kontextwissen zu Ihrem Unternehmen, Ihren Kunden und Umfeld sind von besonderer Bedeutung.
- 4 Befassen Sie sich mit den für die Implementierung neuer Methoden erforderlichen Change-Prozessen zum Abbau etwaiger Akzeptanz- und Nutzungsbarrieren.

haben, dass auch diese sich irren, d.h. fehlerhafte Vorhersagen generieren können (vgl. Dietvorst et al., 2015). Dieses Phänomen ist deshalb von grosser Bedeutung, da eine perfekte Vorhersage auch mit komplexen Modellen und Methoden nicht erreicht werden kann (vgl. Dietvorst et al., 2015). Allgemeine Gründe für eine Ablehnung sind dabei vielfältig. Sie reichen von mangelndem Vertrauen in die Algorithmen bis hin zu kognitiven Verzerrungen (Bias), wie übermässiges Vertrauen in das subjektive «Bauchgefühl» (Overconfidence-Bias) (vgl. Logg et al., 2019; Sadun et al., 2017), Satisficing-Effekte, Bestätigungsfehler, Bevorzugung des Status quo sowie irrationalen Reaktionen auf neue Informationen und Evidenzen (vgl. Sadun et al., 2017; Sharma et al., 2014). Darüber hinaus sind häufig die Komplexität der Entscheidungssituation sowie die Intransparenz des Zustandekommens von Ergebnissen bei Verwendung komplexer Algorithmen zentrale Akzeptanzbarrieren (vgl. Sadun et al., 2018; Brynjolfsson & McAfee, 2017). Im Kontext des akquisitorischen Vertriebs dürfte die Aversion dabei aufgrund der Limitiertheit der Vertriebskapazitäten sowie der monetären Bedeutung des individuellen Vertriebs Erfolgs für Vertriebsmitarbeitende besonders stark ausgeprägt sein.

## Anforderungen an Lead-Scoring-Modelle von morgen

Auf Basis des Stands der Forschung sowie der Beobachtungen in der Praxis lassen sich wesentliche Anforderungen an Lead-

Scoring-Modelle und -Prozesse von morgen ableiten. Diese determinieren mitunter auch den weiteren Forschungsbedarf in diesem Themengebiet.

Zunächst gilt für neue Lead-Scoring-Ansätze, dass sie selbstlernend ausgestaltet sein sollten, d.h. von dokumentierten Verkaufsfällen und deren Ausgänge kontinuierlich lernen. Auf dieser Basis lassen sich dynamische Veränderungen und die Komplexität des Kundenverhaltens sukzessive abbilden. Selbstlernend heisst darüber hinaus, dass systematisch neue Datenquellen zur weiteren Informationsanreicherung und Qualifizierung der Leads erschlossen und in die Vorhersage integriert werden. Hier sind insbesondere Verhaltensdaten, beispielsweise das Surfverhalten auf der eigenen Website oder Aktivitäten und Interaktionen auf Social-Media-Plattformen, denkbar. Mittels API-Schnittstellen lassen sich solche Daten direkt an die Prognosemodelle übermitteln und für die Parametrisierung verfügbar machen, um die Vorhersage in Echtzeit zu konkretisieren.

Darüber hinaus sollten Ansätze immer probabilistisch sein und eine sinnvolle Interpretation erlauben (z.B. Wahrscheinlichkeit einer Opportunity-Conversion), informations- und leadquellenübergreifend ausgestaltet sein und möglichst sämtliche verfügbare Verhaltens- und Demografiedaten integrieren sowie dabei nur solche Daten verwenden, die zum Zeitpunkt der Prognoseerstellung auch tatsächlich verfügbar sind. In diesem Zusammenhang sind skalierbare Ansätze erforderlich, die mit unterschiedlichem Input arbeiten, auch bei wenigen verfügbaren Daten zu verlässlichen Ergebnissen kommen und nach Möglichkeit sowohl Opportunity-Konversions- als auch Kaufwahrscheinlichkeiten vorhersagen können.

Vor dem Hintergrund der vermuteten, im Vertriebsbereich besonders stark ausgeprägten Algorithmus-Aversion könnten zudem XAI-Modelle, die den Anwenderinnen und Anwendern nachvollziehbar aufzeigen, warum ein Lead hoch

priorisiert wird, dazu beitragen, Implementierungshürden abzubauen.

«The research into the acceptance of decision support systems [...] shows that users are more likely to adhere to recommendations when an explanation facility is available [...].»

(Bohanec et al., 2017, S. 416)

Entgegen einiger Ansichten in der Literatur sollten diese Ansätze dabei zwar vollautomatisiert ablaufen, jedoch sollte gleichzeitig die Möglichkeit eines manuellen Eingriffs durch Menschen bestehen, im Sinne einer Mensch-Maschinen-Kollaboration. So kann einerseits zusätzliche Expertise bspw. bei Sonderfällen integriert werden, andererseits kann die Akzeptanz und Nutzung auf Seite der Mitarbeitenden gesteigert werden, indem attributionale Effekte Berücksichtigung finden. Ergänzend dazu gilt es, adäquate organisatorische Strukturen zu entwickeln, die zum Abbau von Akzeptanz- und Nutzungsbarrieren auf Individualebene beitragen können. Diese können beispielsweise Anreizsysteme oder Kommunikationsmassnahmen in Form von Success-Stories und Storytelling umfassen. Zur Akzeptanz von Lead-Scoring-Modellen besteht im Allgemeinen noch erheblicher Forschungsbedarf. Hier könnten die bewährten Technologieakzeptanzmodelle (z.B. Technology Acceptance Model (TAM)) als theoretische Fundierung zur Erklärung des Phänomens herangezogen werden.

## Fazit

Marketing & Sales Funnel Management ist kein neues Thema. Neu sind jedoch viele der Methoden und Prozesse entlang



Quelle: © Adobe Stock.

des Funnels. Dies trifft auch auf die Aufgabe des Lead-Scorings zu. Der Stand der Forschung zeigt, dass die Wissenschaft mit der Entwicklung neuer, performanter Lösungen begonnen hat, jedoch noch am Anfang steht und in vielen Subbereichen Forschungsbedarf besteht. Ein Blick in die Praxis macht deutlich, dass sich viele Unternehmen nach wie vor auf manuelle/subjektive Modelle stützen, mit all den Nachteilen

und Problemen, die damit verbunden sind. Evidenzbasierte Entscheidungen erscheinen auf dieser Basis fraglich.

Der Beitrag versucht, vor diesem Hintergrund erste Anforderungen an künftige Lead-Scoring-Modelle abzuleiten. Hier sind jedoch weitere Studien erforderlich, die sich im Detail mit den einzelnen Entwicklungen (bspw. XAI) auseinandersetzen. ■

---

## Literatur

- Benhaddou, Y. & Leray, P. (2017). Customer relationship management and small data. Application of bayesian network elicitation techniques for building a lead scoring model. 4th ACS/IEEE International Conference on Computer Systems and Applications (AICCSA 2017) (S. 251–255). <http://dx.doi.org/10.1109/AICCSA.2017.51>
- Bohanec, M., Borštnar, M. & Robnik-Šikonja, M. (2015). Integration of machine learning insights into organizational learning: A case of B2B sales forecasting. 28th Bled eConference (S. 338–352). [https://doi.org/10.1007/978-3-319-38974-5\\_7](https://doi.org/10.1007/978-3-319-38974-5_7)
- Bohanec, M., Borštnar, M. & Robnik-Šikonja, M. (2017). Explaining machine learning models in sales predictions. *Expert Systems with Applications*, 71, 416–428. <http://dx.doi.org/10.1016/j.eswa.2016.11.010>
- Brynjolfsson, E. & McAfee, A. (2017). *Von Managern und Maschinen*. Harvard-Business-Manager, 11, 22–34.
- D’Haen, J. & Van den Poel, D. (2013). Model-supported business-to-business prospect prediction based on an iterative customer acquisition framework. *Industrial Marketing Management*, 42(4), 544–551. <http://dx.doi.org/10.1016/j.indmarman.2013.03.006>
- D’Haen, J., Van den Poel, D., Thorleuchter, D. & Benoit, D. (2016). Integrating expert knowledge and multilingual web crawling data in a lead qualification system. *Decision Support Systems*, 82, 69–78. <http://dx.doi.org/10.1016/j.dss.2015.12.002>
- Dietvorst, B., Simmons, J. & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of experimental psychology*, 144 (1), 114–126. <http://dx.doi.org/10.1037/xge0000033>
- Dordevic, A. (2019). Optimizing of digital marketing processes through modeling of lead-scoring. *International Scientific Conference on Information Technology and Data Related Research (Sinteza 2019)* (S. 32–37). <http://dx.doi.org/10.15308/Sinteza-2019-32-37>
- Duncan, B. & Elkan, C. (2015). Probabilistic modeling of a sales funnel to prioritize leads. 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (S. 1751–1758). <http://dx.doi.org/10.1145/2783258.2788578>
- Eitle, V. & Buxmann, P. (2019). Business analytics for sales pipeline management in the software industry: A machine learning perspective. 52nd Hawaii International Conference on System Sciences (S. 1013–1022). <http://dx.doi.org/10.24251/HICSS.2019.125>
- Gabryel, M., Damaševičius, R. & Przybyszewski, K. (2018). Application of the bag-of-words algorithm in classification the quality of sales leads. *International Conference on Artificial Intelligence and Soft Computing* (S. 615–622). [http://dx.doi.org/10.1007/978-3-319-91253-0\\_57](http://dx.doi.org/10.1007/978-3-319-91253-0_57)
- Gebhardt, M. & Gebhardt, L. (2019). Datenbasierte Ansätze der Lead-Generierung. *Marketing Review* St. Gallen, 36(5), 76–82.
- Logg, J., Minson, J. & Moore, D. (2019). Algorithm appreciation: People prefer algorithmic to human judgment. *Organizational Behavior and Human Decision Processes*, 151, 90–103. <https://doi.org/10.1016/j.obhdp.2018.12.005>
- Marvasti, N., Huhtala, J.-P., Yousefi, Z., Vaniala, I., Upreti, B., Malo, P., Kaski, S. & Tikkanen, H. (2021). Is this company a lead customer? Estimating stages of B2B buying journey. *Industrial Marketing Management*, 97, 126–133. <http://dx.doi.org/10.1016/j.indmarman.2021.06.003>
- Monat, J. (2011). Industrial sales lead conversion modelling. *Marketing Intelligence & Planning*, 29 (2), 178–194. <http://dx.doi.org/10.1108/02634501111117610>
- Moncrief, W. & Marshall, G. (2005). The evolution of the seven steps of selling. *Industrial Marketing Management*, 34, 13–22. <http://dx.doi.org/10.1016/j.indmarman.2004.06.001>
- Mortensen, S., Christison, M., Li, B., Zhu, A. & Venkatesan, R. (2019). Predicting and defining B2B sales success with machine learning. 2019 Systems and Information Engineering Design Symposium (SIEDS) (S. 1–5). <http://dx.doi.org/10.1109/SIEDS.2019.8735638>
- Nygård, R. & Mezei, J. (2020). Automating lead scoring with machine learning: An experimental study. 53rd Hawaii International Conference on System Sciences (S. 1439–1448). <http://dx.doi.org/10.24251/HICSS.2020.177>
- Paschen, J., Wilson, W. & Ferreira, J. (2020). Collaborative intelligence: How human and artificial intelligence create value along the B2B sales funnel. *Business Horizons*, 63, 403–414. <http://dx.doi.org/10.1016/j.bushor.2020.01.003>
- Rohaani, D., Topan, E. & Groothuis-Oudshoorn, C. (2022). Using supervised machine learning for B2B sales forecasting: A case study of spare parts sales forecasting at an after-sales service provider. *Expert Systems with Applications*, 188, 1–13. <http://dx.doi.org/10.1016/j.eswa.2021.115925>
- Sadun, R., Bloom, N. & van Reenen, J. (2018). Die wichtigste Disziplin. *Harvard Business Review*, 18 (1), 36–45.
- Sadun, R., Bloom, N. & van Reenen, J. (2017). Why do we undervalue competent management: Neither great leadership nor brilliant strategy matters without operational excellence. *Harvard Business Review*, 17 (9/10), 120–127.
- Sharma, R., Mithas, S. & Kankanhalli, A. (2014). Transforming decision-making processes: A research agenda for understanding the impact of business analytics on organisations. *European Journal of Information Systems*, 23 (4), 433–441. <http://dx.doi.org/10.1057/ejis.2014.17>
- Sung, C., Zhang, B., Higgins, C. & Choe, Y. (2016). Data-driven sales leads prediction for everything-as-a-service in the cloud. *IEEE International Conference on Data Science and Advanced Analytics* (S. 557–563). <http://dx.doi.org/10.1109/DSAA.2016.83>
- Syam, N. & Sharma, A. (2018). Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice. *Industrial Marketing Management*, 69, 135–146. <https://doi.org/10.1016/j.indmarman.2017.12.019>
- Thiess, T., Müller, O. & Tonelli, L. (2020). Design principles for explainable sales win-propensity prediction systems. 15th International Conference on Wirtschaftsinformatik. [http://dx.doi.org/10.30844/wi\\_2020\\_c8-thiess](http://dx.doi.org/10.30844/wi_2020_c8-thiess)
- Trailer, B. (2006). Understanding what your sales manager is up against. *Harvard Business Review*, 84, 48–55.
- Yan, J., Gong, M., Sun, C., Huang, J. & Chu, S. (2015a). Sales pipeline win propensity prediction: A regression approach. *IFIP/IEEE International Symposium on Integrated Network Management*, Ottawa, Kanada, 11. – 15. Mai, 854–857. <http://dx.doi.org/10.1109/INM.2015.7140393>
- Yan, J., Zhang, C., Zha, H., Gong, M., Sun, C., Huang, J., Chu, S. & Yang, X. (2015b). On machine learning towards predictive sales pipeline analytics. 29th AAAI Conference on Artificial Intelligence (S. 1945–1951). <http://dx.doi.org/10.1609/aaai.v29i1.9455>