

# Innovations report 2021

Industrielle Gemeinschaftsforschung

IGF-Forschungsvorhaben 20694 N

Integration der durch Business Analytics gewonnenen Erkenntnisse im Managementprozess durch die Sicherung derer Akzeptanz und verzerrungsfreien Interpretation

#### Laufzeit:

01.04.2019 - 31.03.2021

### **Beteiligte Forschungsstelle(n):**

IPRI - International Performance Research Institute gGmbH Stuttgart

Technische Universität München, Lehrstuhl für Strategie und Organisation

iuta.de



# **Schlussbericht**

zu IGF-Vorhaben Nr. 20694 N

# **Thema**

Enabling data-driven decisions - Integration der durch Business Analytics gewonnenen Erkenntnisse im Managementprozess durch die Sicherung deren Akzeptanz und verzerrungsfreien Interpretation

# **Berichtszeitraum**

01.04.2019 - 31.03.2021

# **Forschungsvereinigung**

Institut für Energie- und Umwelttechnik e.V. - IUTA

# Forschungseinrichtung(en)

Forschungsstelle 1: IPRI - International Performance Research Institute gGmbH

Forschungsstelle 2: Technische Universität München, Lehrstuhl für Strategie und Organisation



Gefördert durch:



# **Inhaltsverzeichnis**

1.	Einl	eitu	ng	1
2.	Geç	genü	berstellung angestrebter Ziele und erzielter Ergebnisse	3
2	2.1	Arb	eitspaket 1	. 3
	2.1	.1	Potenzielle Einsatzgebiete	. 4
	2.1	.2	Erhebung der Akzeptanz	. 6
	2.1	.3	Einsatzgebiet-Akzeptanz-Matrix	14
	2.1	.4	Fazit zu Arbeitspaket 1	15
2	2.2	Arb	eitspaket 2	16
	2.2	.1	Einflussfaktoren auf das Akzeptanzsubjekt und Akzeptanzmodell	17
	2.2	.2	Validierung des Akzeptanzmodells	24
	2.2. Ent	-	Experiment zur Ermittlung der Akzeptanz von Algorithmen bei eidungsträgern (Akzeptanzfaktor "Bereitgestellte Erklärung")	26
	2.2	.4	Fazit zu Arbeitspaket 2	32
2	2.3	Arb	eitspaket 3	32
	2.3. von		Identifikation potenzieller Biases (Kognitive Verzerrungen) im Kontext engetriebenen Entscheidungen und Business Analytics	33
	2.3	.2	Strukturierung der Erkenntnisse (Biases)	37
	2.3. date	_	Katalog validierter Biases (kognitiver Verzerrungen) bei der etriebenen Entscheidungsfindung	51
	2.3	.4	Fazit zu Arbeitspaket 3	55
2	2.4	Arb	eitspaket 4	56
	2.4	.1	Erklärungsmethoden für algorithmische Systeme	56
	2.4. und		Vignettenstudie zur Validierung der identifizierten Erklärungsmethoden ssung des Einflusses auf die Akzeptanz	
	2.4. Kor		Gegenüberstellung der Ergebnisse: Bias-Vermeidungsmethoden im von Business Analytics (inkl. Interviews)	70
	2.4	.4	Fazit zu Arbeitspaket 4	76
2	2.5	Arb	eitspaket 5	77
	2.5. Sch	-	Publikation eines Praxisleitfadens und einer Anleitung als ngsmaßnahmen für kmU	77
	2.5. Der		Modifikation mehrerer etablierter Business Analytics Algorithmen (IT-strator)	78
	2.5	.3	Validierung des Demonstrators	88
	2.5.	.4	Fazit zu Arbeitspaket 5	89

3.	Verwendung der Zuwendung	90
4.	Notwendigkeit und Angemessenheit der geleisteten Arbeit sowie Verwendung	
de	der Zuwendung	
5.	Nutzen, Innovationsbeitrag und Anwendungsmöglichkeiten der erzielten	
Er	gebnisse	93
		93
6.	Plan zum Ergebnistransfer und Einschätzung zur Realisierbarkeit des	
Tra	ansferkonzepts	96
6	6.1 Einschätzung zur Realisierbarkeit des Transferkonzepts	96
6	6.2 Spezifische Transfermaßnahmen während der Projektlaufzeit	96
6	6.3 Spezifische Transfermaßnahmen nach Abschluss des Vorhabens	98
7.	Forschungsstellen	99
F	Forschungsstelle 1: IPRI – International Performance Research Institute gGmbH	99
F	Forschungsstelle 2: Lehrstuhl für Strategie und Organisation (LSO)	99
8.	Förderhinweis1	00
9.	Quellenverzeichnis1	01
10	. Anhang	10

Abbildungsverzeichnis
Abbildung 1: Fragenbogenstudie: Expertise der Teilnehmer
Abbildung 2: Fragenbogenstudie: Umfang des Einsatzes (Auszug) 8
Abbildung 3: Fragenbogenstudie: Anwendungsfälle 8
Abbildung 4: Fragenbogenstudie: Akzeptanz von BA-Ergebnissen im jeweiligen Fachbereich des Teilnehmers (Auszug)
Abbildung 5: Fragenbogenstudie: Gründe für fehlende Akzeptanz 9
Abbildung 6: Umfang des Einsatzes von BA
Abbildung 7: Erfahrung mit BA in Abhängigkeit der Unternehmensgröße (Mitarbeiteranzahl)
Abbildung 8: Akzeptanz von BA-Erkenntnissen
Abbildung 9: Suchprozess
Abbildung 10: Publikationen nach Jahren
Abbildung 11: Modell Akzeptanzfaktoren
Abbildung 12: Fragenbogenstudie – Validierung des Akzeptanzmodells (Teil 1) 24
Abbildung 13: Fragenbogenstudie – Validierung des Akzeptanzmodells (Teil 2) 25
Abbildung 14: Relevanz der Faktoren im Akzeptanzmodell
Abbildung 15: Beispielhaft Darstellung der Aufgabe in Experiment 1 (Gruppe BBI vs. OM)
Abbildung 16: Beispielhaft Darstellung der Aufgabe in Experiment 2 (Gruppe OM). 31
Abbildung 17: Methodik der strukturierten Literaturanalyse (eigene Abbildung) 34
Abbildung 18: Situationsbeschreibung der Vignette
Abbildung 19: Beispiel für eine der genutzten Vignette
Abbildung 20: ADH (adheres to the system's prediction) für verschiedenen  Erklärungen
Abbildung 21: Kalibriertes Vertrauen (in Anlehnung an Lee und See 2004)

# **Tabellenverzeichnis**

Tabelle 1: Umfang des Einsatzes von BA in Abhängigkeit der Erfahrung mit BA, der
Position im Unternehmen und der Unternehmensgröße (Mitarbeiteranzahl
1
Tabelle 2: Akzeptanz von BA Ergebnissen in Abhängigkeit der Erfahrung mit BA, der
Position im Unternehmen und der Unternehmensgröße (Mitarbeiteranzahl
Tabelle 3: Gründe für die Akzeptanz von BA-Ergebnissen aus BA-
Systemanbietersicht1
Tabelle 4: Einsatzgebiete-Akzeptanz-Matrix1
Tabelle 5: Akzeptanz-Einflussfaktoren
Tabelle 6: Kategorisierung der ermittelten Verzerrungen
Tabelle 7: Umsetzung der Erklärungsmethoden6
Tabelle 8: Praxistauglichkeit des Demonstrators und des Leitfadens
Tabelle 9: Personaleinsatz nach A1 (Wissenschaftliche Mitarbeiter) 9
Tabelle 10: IPRI – International Performance Research Institute gemeinnützige
GmbH
Tabelle 11: Lehrstuhl für Strategie und Organisation (LSO)

# 1. Einleitung

Mit der stetig fortschreitenden Digitalisierung verfügen Unternehmen über eine rasant wachsende Anzahl an Daten. So wird bis zum Jahr 2025 eine Verzehnfachung der generierten Datenmengen erwartet(IDC 2017)(IDC 2017). Dies betrifft insbesondere die Unternehmen der produzierenden Industrie, die durch eine stetige Zunahme an Sensorik und der Vernetzung ihrer Produkte, u.a. in Maschinen und Anlagen, Zugang zu einer Vielzahl bisher nicht verfügbarer Daten erhalten. Deren zielgerichtete Nutzung im Rahmen von Business Analytics ist bereits heute ein wesentlicher Einflussfaktor für den Unternehmenserfolg (Seiter 2019). Ein Beispiel für die Potenziale von Business Analytics stellen Warenkorbanalysen dar, auf Basis derer die Unternehmen in die Lage versetzt werden, vorherzusagen, welche Produkte und Services gemeinsam von Kunden nachgefragt werden. Hierauf aufbauend können u.a. das Produktionsprogramm und die Produktionsreihenfolge oder Lagerbestände optimiert werden (Westkamp et al. 2014). Durch diese optimierten Produkt- und Serviceangebote können Umsätze gesteigert und Kosten gesenkt werden (Seiter 2019). Unternehmen haben diese Potenziale erkannt und investieren zunehmend in Business Analytics Software. Allein für das Jahr 2018 erwarten die Anbieter ein Wachstum von 9,9% für ihre Branche (Brynjolfsson und McAfee 2017; Zillmann und Rauch 2017).

In den Unternehmen ist jedoch festzustellen, dass Entscheidungen, trotz des Vorliegens durch Business Analytics gewonnener Erkenntnisse, in knapp der Hälfte aller Fälle dennoch auf Grundlage subjektiver Kriterien getroffen werden (PwC 2016). Hierfür können zwei Arten von Einflussfaktoren verantwortlich gemacht werden: Das bewusste Missachten der gewonnenen Erkenntnisse aufgrund mangelnder Akzeptanz dieser sowie unbewusste Vorurteile und Verzerrungen, sogenannte Biases. Gründe für diese fehlende Akzeptanz können sowohl mit einem sich selbst überschätzenden Management, wie die Studie von Sadun, Bloom und Van Reenen zeigt, und der Komplexität der Business Analytics Algorithmen begründet werden (Sadun et al. 2018). Entscheidungsträger sind sich hierbei häufig im Unklaren darüber, wie die Ergebnisse – auf Basis komplexer Algorithmen – ermittelt werden (Brynjolfsson und McAfee 2017). Unbewusste Einflüsse im Kontext von durch Business Analytics gewonnener Erkenntnisse umfassen u.a. das Versagen, die eigenen Gedanken an neue Beweise und Informationen (schnell genug) anzupassen (der sogenannte Konservatismus Bias) oder eine selektive Wahrnehmung, d.h. eigene Erfahrungen und Hintergründe können einen Tunnelblick erzeugen (Sadun et al. 2017; Sharma et al. 2017; Makridakis 1990). Ziel des vorliegenden Forschungsvorhabens war es daher, die Unternehmen der produzierenden Industrie, u.a. im Maschinen- und Anlagenbau, zu befähigen, die durch Business Analytics gewonnenen Erkenntnisse erfolgreich nutzen zu können. Damit werden sie in die Lage versetzt, Entscheidungen evidenzbasiert zu treffen und somit subjektive, unbewusst verzerrte Entscheidungen zu reduzieren.

Im vorliegenden Forschungsvorhaben wurden zu diesem Zweck zu Beginn die Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse in den verschiedenen Phasen des Managementprozesses und deren Einflussfaktoren in den produzierenden

Unternehmen ermittelt. Anschließend wurden Biases im Kontext der durch Business Analytics gewonnenen Erkenntnisse auf Managementebene identifiziert und strukturiert. Aus diesen Erkenntnissen wurden anschließend Implikationen zur Steigerung der Akzeptanz und Reduktion von Biases für die Nutzung von durch Business Analytics gewonnenen Erkenntnissen abgeleitet und für kmU mittels einem IT-Demonstrator und Schulungsmaßnahmen aufbereitet.





# IPRI – International Performance Research Institute gGmbH

Königstraße 5, 70173 Stuttgart



# Lehrstuhl für Strategie und Organisation der Technischen Universität München

Arcisstraße 21, 80333 München

Das IGF-Vorhaben 20694 N der Forschungsvereinigung Institut für Energie- und Umwelttechnik e.V. – IUTA wird über die AiF im Rahmen des Programms zur Förderung der industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Energie (BMWi) aufgrund eines Beschlusses des Deutschen Bundestages gefördert.

Gefördert durch:





aufgrund eines Beschlusses des Deutschen Bundestages

# 2. Gegenüberstellung angestrebter Ziele und erzielter Ergebnisse

# 2.1 Arbeitspaket 1

Das Arbeitspaket 1 "Akzeptanz durch Business Analytics gewonnener Erkenntnisse" diente der Ermittlung der aktuellen Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse im Managementprozess zur Ableitung einer Einsatzgebiet-Akzeptanz-Matrix.

Durchgeführte Arbeiten	Erzielte Ergebnisse
Literaturreview, Expertengespräche und - Workshops zur Identifikation potenzieller <b>Einsatzgebiete von Business Analytics</b> in den Phasen des Managementpro- zesseses.	<ul> <li>Identifizierte und validierte Einsatzgebiete entlang des Managementprozesses (Logistik, Produktion, Marketing / Vertrieb, Service, Infrastruktur, Human Resources, Research &amp; Development, Einkauf) und Beschreibung von jeweiligen Use Cases.</li> </ul>
Fragebogenstudie zur Erhebung der Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse für die in Arbeitsschritt 1 identifizierten potenziellen Einsatzgebiete im Managementprozess.	<ul> <li>Durchführung einer web-basierten Befragung von Experten und Anwendern im Bereich Business Analytics (<a href="https://ww3.uni-park.de/uc/ED3/">https://ww3.uni-park.de/uc/ED3/</a>) zur Erhebung der Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse. Verteilung der Fragebogenstudie durch E-Mail-Anfrage von über 5500 Unternehmen, Verteilung an die Unternehmens des Projektbegleitenden Ausschusses und im Rahmen von öffentlichen XING- / LinkedIn-Postings.</li> <li>Semistrukturierte Befragung von BA-Systemanbietern.</li> </ul>
Zusammenführung der in Arbeitsschritt 1 ermittelten Einsatzgebiete und der in Arbeitsschritt 2 analysierten Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse in einer Einsatzgebiet-Akzeptanz-Matrix.	Konzeption einer Einsatzgebiet- Akzeptanz-Matrix auf Basis der durchgeführten Arbeiten.

Zunächst wurden potenzielle Einsatzgebiete von BA mittels theoretischer Ableitung aus der Literatur unter Zuhilfenahme der Wertkette nach Porter sowie durch 10 Expertengespräche (Q2-Q4 2019) und einem Workshop (Q3 2019) mit Vertretern des projektbegleitenden Ausschusses identifiziert. Darauf aufbauend wurde die Akzeptanz der

durch BA gewonnenen Erkenntnisse, für die in Arbeitsschritt 1 identifizierten, potenziellen Einsatzgebiete im Managementprozess erhoben. Hierzu wurde ein Fragebogen entwickelt, der sowohl die Akzeptanz von Prozessen als auch die Akzeptanz und Umsetzung von datengetriebenen Ergebnissen erfasst. Der Fragebogen wurde weitläufig an über 5500 Unternehmen verteilt und es wurden 51 Rückläufer generiert. Zur weiteren qualitativen Exploration von Einflussfaktoren für die Akzeptanz von BA-Ergebnissen wurden zudem 14 semistrukturierte Interviews mit Mitarbeitern von BA-Systemanbietern durchgeführt. Die Ergebnisse des Fragebogens wurden abschließend in eine Einsatzgebiet-Akzeptanz-Matrix überführt.

# 2.1.1 Potenzielle Einsatzgebiete

Abweichend zur Beschreibung im Projektantrag wird aufgrund der detaillierteren Darstellung der einzelnen Unternehmensbereiche und der höheren Praxisrelevanz statt dem St. Gallener Management Modell die Wertkette nach Porter als Basis für die Identifikation von Einsatzgebieten genutzt.

#### Wertkette nach Porter

Um die Sinnhaftigkeit des Einsatzes von BA Anwendungen bewerten zu können, wurden die Anwendungsfälle anhand der Wertekette von Porter erhoben. Eine Wertekette ist eine Darstellung der Tätigkeitsfelder eines Unternehmens. Eine Wertekette setzt sich aus verschiedenen Teilsystemen zusammen, die zur Produktion von Gütern oder zur Erbringung von Dienstleistungen benötigt werden. Die Wertkette nach Porter ist ein strategisches Management-Werkzeug zur Analyse der Wertekette eines Unternehmens. Dieses Modell unterteilt die innerbetriebliche Wertekette in primäre und sekundäre Aktivitäten. Zunächst werden die primären oder wertschöpfenden Aktivitäten beschrieben.

- Die Eingangslogistik umfasst die Annahme, Lagerung und Bestandskontrolle der Rohstoffe eines Unternehmens. Für einen Automobilhersteller beinhaltet dies bspw. den Empfang und die Lagerung von Produkten der Zulieferer.
- Zum Bereich Produktion gehören Verfahren zur Umwandlung von Rohstoffen in ein fertiges Produkt. Im obigen Automotive-Beispiel gehört hierzu die Fertigung der Fahrzeuge.
- Marketing und Vertrieb umfasst die Verbesserung der Sichtbarkeit und die Ansprache geeigneter Kunden. Hierbei handelt es sich um alle Aktivitäten, die dazu beitragen, einen Verbraucher vom Kauf eines Produkts oder einer Dienstleistung eines Unternehmens zu überzeugen. Ein Automobilhersteller schaltet bspw. Fernsehwerbung und betreibt Autohäuser.
- Alle Aktivitäten zur Verteilung eines Endprodukts an einen Verbraucher werden als ausgehende Logistik betrachtet. Dies schließt die Auslieferung des Produkts ein, umfasst aber auch Lager- und Vertriebssysteme und kann extern oder intern erfolgen. Die Überstellung eines Autos zum Kunden ist eine beispielhafte Aktivität.
- Der Bereich Service umfasst alle Aktivitäten, die die Wartung von Produkten betreffen und dem Kundenservice, Rückerstattung oder Austausch zuzuordnen

sind. Für einen Automobilhersteller beinhaltet dies bspw. Reparaturen oder eine Garantieleistung.

Weiter werden die sekundären oder unterstützenden Aktivitäten beschrieben.

- Der Bereich Infrastruktur beinhaltet alle grundlegenden Funktionen, die die Aufrechthaltung des Betriebs erst ermöglichen. Hierzu zählen bspw. alle buchhalterischen, rechtlichen und administrativen Funktionen.
- Einstellung, Bindung und Entwicklung von Mitarbeitern sind die wesentlichen Aufgaben des Bereichs **Human Ressource**.
- Forschung und Entwicklung (R&D) umfasst die Konzeption und Entwicklung von Produkten und Prozessen.
- Der Einkauf ist für die Beschaffung von Ressourcen und Dienstleistungen für das Unternehmen zuständig.

# Identifikation von Anwendungsgebieten von BA

Mittels einer Literaturrecherche, Interviews und einem Workshop mit Teilnehmern des projektbegleitenden Ausschusses wurden relevante Anwendungsfälle von BA in den jeweiligen Aktivitätsfeldern identifiziert (vgl. Anhang 1). Die identifizieren Anwendungsfälle wurden mit dem projektbegleitenden Ausschuss diskutiert und dienten im weiteren Verlauf des Forschungsvorhabens als Referenz für Anwendungsbeispiele (z.B. AP1: Fragebogenstudie, AP3: Vignettenstudie, AP4: Maßnahmenkatalog). Die identifizierten Anwendungsfälle decken sich mit dem Ziel von BA, Problemstellungen im gesamten Managementzyklus von Planung, Steuerung und Kontrolle evidenzbasiert zu lösen. Unter Evidenzen werden begründete, objektive Einsichten in einen Sachverhalt verstanden. Diese Evidenzen werden auf Basis von Daten aus verschiedensten Bereichen innerhalb und außerhalb des Unternehmens mittels Algorithmen aus den Bereichen Statistik, Data Mining und Machine Learning gewonnen. Durch die Anwendung von BA können Entscheidungen faktenbasiert getroffen und komplexe Szenarios visualisiert werden (Seiter 2019). Typische Anwendungsfälle von BA in kmU umfassen vor diesem Hintergrund unter anderem:

- **Controlling**: BA-Anwendungen finden sich in präzisen Prognosen von steuerungsrelevanten Umsatz- und Kostenkennzahlen, in der Quantifizierung strategischer Optionen, der Bewertung von Business Cases.
- Vertrieb: Im Rahmen der Vertriebsunterstützung werden in Echtzeit Kundeninformationen auf mobilen Endgeräten bereitgestellt, die Servicetechniker befähigen, aktiv den Vertrieb von Produkt- und Serviceangeboten durchzuführen.
- Logistik: BA-Lösungen werden zur Abbildung typischer Lagerprozesse (Einlagerung, Kommissionierung, etc.) eingesetzt, sodass Abläufe und Warenbewegungen transparenter nachzuverfolgen sind. Dadurch reduzieren kmU Durchlaufzeiten, Fehlerquoten sowie den administrativen Aufwand.
- **Produktion**: kmU nutzen BA zur Optimierung von Fertigungsprozessen. Im Rahmen der prädiktiven Fertigungsprozess-Analyse werden Ursachenanalysen und Prognosen über den gesamten Fertigungsprozess datengetrieben durchgeführt, um z.B. systematisch die Einflussfaktoren für eine Verschlechterung der Fertigungsqualität zu identifizieren.

• Forschung und Entwicklung: BA wird von kmU eingesetzt, um Prototypen in Echtzeit auf Fehler mit kürzester Latenz zu prüfen, um schnellstmöglich für Korrekturen an Prototypen zu sorgen.

# 2.1.2 Erhebung der Akzeptanz

Zur Messung und Bewertung der Akzeptanz der durch BA gewonnenen Erkenntnisse für die identifizierten Einsatzgebiete wurde eine Umfrage durchgeführt, die sowohl die Akzeptanz der Prozesse, als auch die Akzeptanz datengetriebener Ergebnisse erfasst (vgl. <a href="https://ww3.unipark.de/uc/ED3/">https://ww3.unipark.de/uc/ED3/</a>). Zielpersonen des Fragebogens waren Entscheidungsträger aus Unternehmen des Maschinen- und Anlagenbaus sowie Entwickler oder Anwender von BA-Anwendungen zur Entscheidungsunterstützung. Das Ziel war es, eine möglichst breite Anzahl an Entscheidungsträgern zu erreichen. Hierfür sollten mindestens 50 auswertbare Fragebögen für das Forschungsprojekt generiert werden. Vor diesem Hintergrund wurde der Fragebogen durch E-Mail-Anfrage an über 5500 Unternehmen, Verteilung an die Unternehmen des Projektbegleitenden Ausschusses und im Rahmen von öffentlichen XING- / LinkedIn-Postings verteilt. Die abschließende Auswertung des Fragebogens erfolgte mit Hilfe statistischer Auswertungsverfahren, insbesondere deskriptiver Statistiken und Frequenzanalysen.

Der Fragebogen ist in vier Teile gegliedert und zielt neben der Erfassung der Einsatzhäufigkeit von BA auf die Messung der Akzeptanz von BA in den jeweiligen Gebieten ab. Zudem wird das in AP2 auf Basis einer umfassenden Literaturrecherche erstellte Modell von Einflussfaktoren in einem Zwischenschritt validiert um die Umfrageteilnehmer für die Thematik "Akzeptanz von BA" zu sensibilisieren. Abschließend werden Informationen zur Erfahrung im Umgang mit Business Intelligence- und BA-Anwendungen und weitere demographische Daten abgefragt. Die Bearbeitungszeit betrug ca. 15 Minuten. Der Fragebogen wurde in der Unipark-Umgebung erstellt und war wie folgt aufgebaut:

# Fragebogen Teil I: Einsatzgebiete von BA

Nachdem konkrete Anwendungsfälle für BA identifiziert wurden, soll im Rahmen des ersten Umfrageteils die Grundlage für eine Quantifizierung der Einsatzhäufigkeit nach den gleichen Unternehmensbereichen erfolgen. Da nicht davon auszugehen ist, dass jeder Umfrageteilnehmer über die Einsatzhäufigkeit von BA informiert ist, wird zunächst abgefragt, in welchen Unternehmensbereichen der Umfrageteilnehmer sich selber eine BA-Expertise attestiert (vgl. Abbildung 1). Es stehen dafür fünf Antwortmöglichkeiten zur Verfügung (keine Expertise, wenig Expertise, mittelmäßige Expertise, hohe Expertise, sehr hohe Expertise). Nur in den Bereichen, in denen die Expertise als mittelmäßig, hoch oder sehr hoch eingeschätzt wird, wird nach der Einsatzhäufigkeit von BA gefragt. Damit wird verhindert, dass Umfrageteilnehmer außerhalb ihrer Expertise subjektive Einschätzungen bzgl. der Einsatzhäufigkeit abgeben. Die eigentliche Abfrage der Einsatzhäufigkeit erfolgt nach dem gleichen Prinzip (vgl. Abbildung

2). Auch zur Bewertung der Einsatzhäufigkeit stehen dem Teilnehmer fünf Antwortmöglichkeiten (gar nicht eingesetzt, wenig eingesetzt, mittelmäßig eingesetzt, häufig eingesetzt, sehr häufig eingesetzt) zur Verfügung.

Abschließend werden die Teilnehmer nach konkreten Anwendungsfällen für die Einsatzgebiete gefragt. Wurde die Frage nach der Einsatzhäufigkeit zuvor mit gar nicht oder wenig beantwortet, wird der Teilnehmer nach Gründen für diese geringe Einsatzhäufigkeit gefragt (vgl. Abbildung 3). Durch diese Aufteilung werden sowohl weitere konkrete Anwendungsfälle ermittelt um die Ergebnisse von AS1 zu ergänzen und zudem erste Hürden und Barrieren im Kontext des Einsatzes von BA ermittelt. Um den Fragebogen so schlank wie möglich zu halten, standen den Umfrageteilnehmern optional zusätzliche Informationen zur Wertkette nach Porter und Beispiele zu möglichen BA-Anwendungen zur Verfügung (vgl. Anhang 2).









Teil 1: Einsatzgebiete von Business Analytics

Unter Business Analytics (BA) ist die systematische und kontinuierliche Auswertung betrieblich anfallender Daten (z.B. im Rahmen von Reports oder digitalen Anwendungen) zu verstehen. <u>Hier finden Sie weitere Informationen zu den Unternehmensbereichen und Beispiele für BA-Anwendungen.</u>

Wie würden Sie Ihre BA-Expertise für die folgenden Unternehmensbereiche einschätzen? Mittelmäßige Sehr hohe Keine Expertise Wenig Expertise Hohe Expertise Expertise Expertise Logistik 0 0 0 0 0 0 0 0 Produktion 0 0 Marketing / Vertrieb 0 0 0 0 0 Service 0 0 0 0 0 Infrastruktur 0 0 0 0 0 Human Resources 0 0 0 0 0 Research & Development 0 0 0 0 0 Einkauf

11% WEITER

Abbildung 1: Fragenbogenstudie: Expertise der Teilnehmer

#### Teil 1: Einsatzgebiete von Business Analytics

Unter Business Analytics (BA) ist die systematische und kontinuierliche Auswertung betrieblich anfallender Daten (z.B. im Rahmen von Reports oder digitalen Anwendungen) zu verstehen. <u>Hier finden Sie weitere Informationen zu den Unternehmensbereichen und Beispiele für BA-Anwendungen.</u>

In welchem Umfang wird BA in den folgenden Unternehmensbereichen in Ihrem Unternehmen eingesetzt?

	Gar nicht eingesetzt	Wenig eingesetzt	Mittelmäßig eingesetzt	Häufig eingesetzt	Sehr häufig eingesetzt
Logistik	0	0	0	0	0
Infrastruktur	0	0	0	0	0
Research & Development	0	0	0	0	0
Einkauf	0	0	0	0	0

# Abbildung 2: Fragenbogenstudie: Umfang des Einsatzes (Auszug)

Teil 1: Einsatzgebiete von Business Analytics
Unter Business Analytics (BA) ist die systematische und kontinuierliche Auswertung betrieblich anfallender Daten (z.B. im Rahmen von Reportsoder digitalen Anwendungen) zu verstehen. <u>Hier finden Sie weitere Informationen zu den Unternehmensbereichen und Beispiele für BA Anwendungen.</u>
Bitte nennen Sie konkrete Anwendungsfälle in Ihrem Unternehmen für BA in der Logistik. (optional)
Aus welchen Gründen wird BA in Ihrem Unternehmen im Bereich Infrastruktur gar nicht oder nur wenig

#### Abbildung 3: Fragenbogenstudie: Anwendungsfälle

angewandt? (optional)

### Fragebogen Teil II: Akzeptanz von BA Erkenntnissen

Im zweiten Teil des Fragebogens wird die Akzeptanz der durch BA erlangten Erkenntnisse im Entscheidungsprozess bewertet. Zunächst wird ein einheitliches Begriffsverständnis geschaffen. Im Rahmen des Forschungsvorhabens werden Entscheidungsträger definiert als Personen mit der Verantwortung und der Befugnis Entscheidungen in einer Organisation zu treffen, vor allem jene, welche die künftige Richtung und Strategie des Unternehmens betreffen. Im Rahmen dieses Projektes werden Entscheidungsträger betrachtet, die ihre Entscheidungen auf Basis von Ergebnissen aus BA-Verfahren treffen. Unter BA-Ergebnissen werden z.B. konkrete Handlungsempfehlun-

gen (Präskriptive Analytics) oder zu interpretierende Informationen mit einem deskriptiven oder prädiktiven Charakter verstanden, die z. B. via Reports oder Dashboard-Anzeigen zur Verfügung gestellt werden.

Zur Bewertung der Akzeptanz von BA-Ergebnissen bei Entscheidungsträgern stehen den Teilnehmern wieder fünf Antwortmöglichkeiten (gar nicht akzeptiert, wenig akzeptiert, mittelmäßig akzeptiert, häufig akzeptiert, sehr häufig akzeptiert) zur Verfügung (vgl. Abbildung 4). Basierend auf den im ersten Teil der Befragung angegebenen Kompetenzen wird auch hier eine Eingrenzung auf die jeweils relevanten Unternehmensbereiche vorgenommen.

Um Gründe für fehlende Akzeptanz zu ermitteln, wurden für die Unternehmensbereiche, für die eine geringe Akzeptanz (gar nicht akzeptiert, wenig akzeptiert) angegeben wurde, eine optionale Freifeldeingabe integriert (Abbildung 5).

#### Teil 3: Akzeptanz von Business Analytics Erkenntnissen

Im Rahmen des Forschungsvorhabens definieren wir eine/n Entscheidungsträger/in als eine Person, mit der Verantwortung und der Befugnis, Entscheidungen in einer Organisation zu treffen, vor allem jene, welche die künftige Richtung und Strategie des Unternehmens betreffen. Unter diesem Hinblick betrachten wir Entscheidungsträger, die ihre Entscheidungen auf Basis von Ergebnissen aus Business Analytics Verfahren treffen. Unter Business Analytics Ergebnissen verstehen wir z.B. konkrete Handlungsempfehlungen (Präskriptive Analytics) oder zu interpretierende Informationen mit einem deskriptiven oder prädiktiven Charakter, die z. B. via Reports oder Dashboard-Anzeigen zur Verfügung gestellt werden.



Wie akzeptiert sind BA-Ergebnisse bei Entscheidungsträgern in Ihrem Unternehmen im jeweiligen Unternehmensbereich?

	Gar nicht akzeptiert	Wenig akzeptiert	Mittelmäßig akzeptiert	Ziemlich akzeptiert	Immer akzeptiert	Kann ich nicht einschätzen
Logistik	0	0	0	0	0	0
Infrastruktur	0	0	0	0	0	0
Research & Development	0	0	0	0	0	0
Einkauf	0	0	0	0	0	0

# Abbildung 4: Fragenbogenstudie: Akzeptanz von BA-Ergebnissen im jeweiligen Fachbereich des Teilnehmers (Auszug)

#### Teil 3: Akzeptanz von Business Analytics Erkenntnissen

Im Rahmen des Forschungsvorhabens definieren wir eine/n Entscheidungsträger/in als eine Person, mit der Verantwortung und der Befugnis, Entscheidungen in einer Organisation zu treffen, vor allem jene, welche die künftige Richtung und Strategie des Unternehmens betreffen. Unter diesem Hinblick betrachten wir Entscheidungsträger, die ihre Entscheidungen auf Basis von Ergebnissen aus Business Analytics Verfahren treffen. Unter Business Analytics Ergebnissen verstehen wir z.B. konkrete Handlungsempfehlungen (Präskriptive Analytics) oder zu interpretierende Informationen mit einem deskriptiven oder prädiktiven Charakter, die z.B. via Reports oder Dashboard-Anzeigen zur Verfügung gestellt werden.

us welchen Gründen werden Ergebnisse aus BA in Ihrem Unternehmen im Einkauf von Entscheidungsträgern gar cht oder nur wenig akzeptiert? (optional)	r
	_

# Fragebogen Teil III - Fragen zur Person

Im letzten Teil der Fragebogenstudie werden die sozio-demographische Parameter der Teilnehmer erhoben. Hierbei werden neben den personenbezogenen Daten wie Geschlecht, Alter, Bildungsstand und Erfahrungen mit BA auch Tätigkeitsbezogene Daten wie Position, Branche und Unternehmensgröße erhoben.

# Umfrageteilnehmer

Insgesamt resultierten die weitreichenden Anfragen zur Teilnahme an der Fragebogenstudie in 51 verwertbaren Rückläufern. Von allen Teilnehmern waren 82,4 Prozent (N=42) männlich und 17,6 Prozent (N=9) weiblich. Im Durchschnitt waren die Teilnehmer 38,3 Jahre alt, der jüngste war 25, der älteste 66 Jahre alt. Ein großer Anteil der Teilnehmer hatte Führungsverantwortung (N=33).

# Auswertung Teil I: Einsatzgebiete von BA

Die Abfrage des Umfangs des Einsatzes von BA in den einzelnen Aktivitätsbereichen erfolgt durch die Bewertung der Einsatzhäufigkeit basierend auf fünf Antwortmöglichkeiten, die jeweils mit einem Zahlenwert verknüpft sind (gar nicht eingesetzt = 1, wenig eingesetzt = 2, mittelmäßig eingesetzt = 3, häufig eingesetzt = 4, sehr häufig eingesetzt = 5). Für die einzelnen Aktivitätsbereiche wird anschließend der Mittelwert gebildet um eine Betrachtung des Einsatzumfangs von BA zu ermöglichen (vgl. Abbildung 6). Die Durchschnittswerte liegen in dem Bereich von 2,7 (HR) bis 3,6 (Marketing/Vertrieb) bei einem Durschnitt von 3,2 über alle Aktivitätsbereiche. Gerade im Bereich Service, HR und R&D wird der Umfang des Einsatzes als relativ niedrig eingeschätzt. Dies liegt laut der Freitextantworten (vgl. Anhang 3) daran, dass im Service und der R&D wenige Daten anfallen, da rein manuell gearbeitet wird. In HR-Bereich sind Bedenken hinsichtlich des Datenschutzes eine mögliche Ursache.

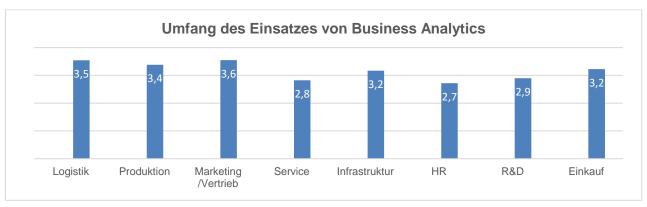


Abbildung 6: Umfang des Einsatzes von BA

Des Weiteren wurde der Umfang des Einsatzes von BA in Abhängigkeit der Erfahrung mit BA, der Position im Unternehmen und der Unternehmensgröße (Mitarbeiteranzahl) untersucht (vgl. Tabelle 1). Die Erfahrung der Befragten korreliert dabei positiv mit der Einschätzung des Umfangs der Verwendung von BA. Ob ein Teilnehmer Führungserfahrung hat spielt hingegen kaum eine Rolle. Die Unternehmensgröße, gemessen an

der Mitarbeiterzahl spielt wiederum eine größere Rolle. Teilnehmer aus größeren Unternehmen schätzen den Umfang des Einsatzes von BA höher ein, als Teilnehmer aus kleineren Unternehmen.

Tabelle 1: Umfang des Einsatzes von BA in Abhängigkeit der Erfahrung mit BA, der Position im Unternehmen und der Unternehmensgröße (Mitarbeiteranzahl)

Erfahrung	Anzahl	Logistik	Produktion	Marketing/Vertrieb	Service	Infrastruktur	HR	R&D	Einkauf	Ø
Keine Erfahrung	4	2.5	2.0	2.2	4.0	2.5	0.0	2.0	2.0	
Begrenzte Erfahrung	10	3,5	3,6	3,3	1,8	3,5	2,0	2,0	3,0	2,83
Etwas Erfahrung	19	3,1	3,4	3,8	2,7	3,1	2,6	3,1	3,4	3,17
Ausführliche Erfahrung	16	3,9	3,2	3,5	3,4	3,1	3,0	3,4	3,1	
Umfassende Erfahrung	2	·	· 			· 				3,33
Position										
Top-Level-Manager / Executive Manager	8									
Senior Manager	6	3,3	3,5	3,7	2,9	3,2	2,6	3,0	3,2	3,16
Mittlerer Manager	5									
Manager	14									
Mitarbeiter	18	4,0	3,2	3,6	3,0	3,5	2,8	2,6	3,5	3,26
Unternehmensgröße (N	litarbeiter	anzahl)								
Klein (0 – 500)	27	3,5	3,4	3,2	2,8	2,4	2,6	2,7	2,9	2,93
Groß (< 500)	19	3,7	3,4	4,1	2,8	3,6	2,9	3,3	3,9	3,45

Der Zusammenhang zwischen der Erfahrung mit BA in Abhängigkeit von der Unternehmensgröße (Mitarbeiteranzahl) ist in Abbildung 7 dargestellt. In sehr kleine Unternehmen (0-10 MA) ist die durchschnittliche Erfahrung ähnlich groß, wie bei größeren Unternehmen (<500 MA). In mittelgroße Unternehmen (11-500 MA) hingegen ist die durchschnittliche Erfahrung mit BA geringer. Dieser Zusammenhang unterstützt die These, dass BA in Startups mit einer geringen Mitarbeiterzahl und in Großunternehmen einen umfangreicheren Einsatz erfährt und die Mitarbeiter deshalb mehr Erfahrung im Bereich BA aufweisen.

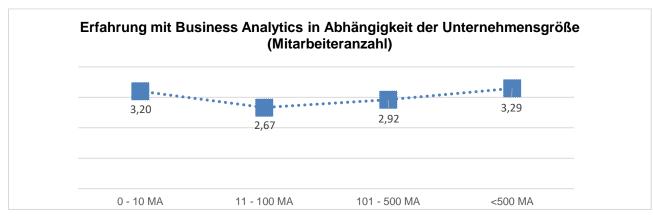


Abbildung 7: Erfahrung mit BA in Abhängigkeit der Unternehmensgröße (Mitarbeiteranzahl)

# Auswertung Teil II: Akzeptanz von BA-Erkenntnissen

Zur Bewertung der Akzeptanz von BA-Ergebnissen bei Entscheidungsträgern standen den Teilnehmern wieder fünf mit Zahlenwerten verknüpfte Antwortmöglichkeiten (gar nicht akzeptiert = 1, wenig akzeptiert = 2, mittelmäßig akzeptiert = 3, häufig akzeptiert = 4, sehr häufig akzeptiert = 5) zur Verfügung. Für die quantitative Bewertung der einzelnen Unternehmensbereiche wurde anschließend jeweils der Mittelwert gebildet um somit eine Betrachtung der Akzeptanz von BA Ergebnissen zu ermöglichen. Die Durchschnittswerte liegen in dem Bereich von 3,3 (Service) bis 4,2 (Logistik) bei einem Durschnitt von 3.8 über alle Aktivitätsbereiche. Der vergleichsweise niedrige Wert im Service könnte laut der Freitextkommentare (vgl. Anhang 4) durch fehlenden sinnvolle Use Cases im Service insbesondere bei kleineren Unternehmen begründet werden.

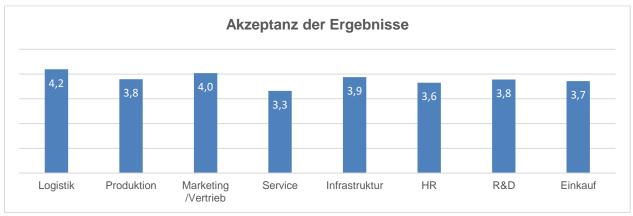


Abbildung 8: Akzeptanz von BA-Erkenntnissen

In einer zusätzlichen Analyse wurde die Akzeptanz von BA-Ergebnissen in Abhängigkeit mit der Erfahrung mit BA, der Position im Unternehmen und der Unternehmensgröße (Mitarbeiteranzahl) untersucht (vgl. Tabelle 2). Die Akzeptanz der Befragten ist am höchsten, wenn der Teilnehmer geringfügige Erfahrung mit BA hat. Zu den beiden Extremen hin nimmt die Einschätzung der Akzeptanz von BA-Ergebnissen ab. Ob ein Teilnehmer Führungserfahrung hat keinen Einfluss auf die Akzeptanz. Auch die Unternehmensgröße, gemessen an der Mitarbeiterzahl spielt keine Rolle. Teilnehmer aus größeren Unternehmen schätzen die Akzeptanz von BA-Ergebnissen laut der erhobenen Daten ähnlich ein wie Teilnehmer aus kleineren Unternehmen.

Tabelle 2: Akzeptanz von BA Ergebnissen in Abhängigkeit der Erfahrung mit BA, der Position im Unternehmen und der Unternehmensgröße (Mitarbeiteranzahl)

Erfahrung	Anzahl	Logistik	Produktion	Marketing/Vertrieb	Service	Infrastruktur	HR	R&D	Einkauf	Ø
Keine Erfahrung	4	4,3	3,9	4,3	2,8	4,0	2,0	2,7	3,7	3,44
Begrenzte Erfahrung	10	4,3	3,9	4,3	2,0	4,0	2,0	2,1	3,7	3,44
Etwas Erfahrung	19	3,9	3,7	4,4	3,6	4,6	3,8	4,5	3,9	4,03
Ausführliche Erfahrung	16	4,4	3,9	3,8	3,3	3,1	3,7	4,2	3,6	3,75
Umfassende Erfahrung	2	-, .	0,0	-,-	-,-	-, -	-,-	,-	-,-	- ,
Position										
Top-Level-Manager / Executive Manager	8	4,2	3,9	4,2	3,3	3,7	3,4	3,8	3,8	3,79
Senior Manager	6									

Erfahrung	Anzahl	Logistik	Produktion	Marketing/Vertrieb	Service	Infrastruktur	HR	R&D	Einkauf	Ø
Mittlerer Manager	5									
Manager	14									
Mitarbeiter	18	4,1	3,4	3,8	3,3	4,2	4,0	3,5	3,6	3,73
Unternehmensgröße	(Mitarbeiter	anzahl)								
Klein (0 – 500)	27	4,2	4,0	4,1	3,2	4,0	3,7	3,5	3,5	3,76
Groß (< 500)	19	4,2	3,5	4,0	3,4	3,8	3,6	4,3	4,1	3,88

# Semistrukturierte Befragung von BA-Systemanbietern.

Zur weiteren Identifikation von Einflussfaktoren für die Akzeptanz oder auch Nicht-Akzeptanz von BA-Ergebnissen wurde eine zusätzliche qualitative Befragung unter 14 Mitarbeitern von BA-Systemanbietern durchgeführt. Im spezifischen wurden semistrukturierte Interviews (vgl. Anhang 5) mit Key Account Managern und Customer Success Managern durchgeführt, da ihre Hauptaufgabe darin besteht, Endanwender in die Position zu bringen BA-Systeme zu nutzen und somit in engen Kontakt mit ihren Kunden und Anwendern stehen. Daher können sie über ihre Erfahrungen mit Endanwendern, wiederkehrende Probleme ihrer Kunden und Erfolgsfaktoren berichten. Die Struktur der Interviews erfolgte in fünf Schritten. Jeder Schritt bestand aus Hauptfragen, die dem Interview Struktur gaben und wurden durch Folgefragen ergänzt, um mehr Details und Tiefe zu erhalten (Rubin, 2012, S.116-121).

Auf Basis der 14 semistrukturierten Interviews mit Mitarbeitern von BA-Systemanbietern wurden vier übergeordnete und 26 untergeordnete Gründe für die Akzeptanz oder Nicht-Akzeptanz von BA-Ergebnissen identifiziert (siehe Tabelle 3). Auf Individualebene sind unter anderem die Motivation und die Fähigkeiten des Anwenders, auf Organisationsebene Ressourcenverfügbarkeit und Personal, auf Datenebene Zugriff und Performance und übergeordnet Vorgaben zur Nutzung von BA-Systemen und sich verändernde Anforderungen relevant.

Tabelle 3: Gründe für die Akzeptanz von BA-Ergebnissen aus BA-Systemanbietersicht

Ebene	Gründe	Sub-Gründe	Beschreibung
Individual- ebene	Motivation	Zusätzliche Arbeit	Einarbeitungszeit in die Technik neben dem Tagesgeschäft
		Neue Prozesse / Neue Aufgaben	Veränderung des Arbeitsalltags durch neue Aufgaben und Tätigkeiten
		Nicht erkennbarer Mehrwert	Mehrwert in der Nutzung der Technologie ist für den Einzelnen nicht erkennbar
		Alter	Alter des Anwenders als Einflussfaktor
	B.4'		
	Misstrauen	Fehlendes Vertrauen	Mangelndes Vertrauen in die Technologie (auch in Daten und Erkenntnisse)
		Datenschutz	Bedenken wegen mangelnder Datensi- cherheit
		Blackbox	Ungewissheit über die Herkunft der Daten und Erkenntnisse
	Fähigkeiten/Wissen	Fehlende Expertise	Fehlende Affinität/Wissen, die Technologie zu verstehen und anzuwenden
		MangeIndes Training	Unzureichende Schulung zur Nutzung der Technologie

Ebene	Gründe	Sub-Gründe	Beschreibung
		Bedienbarkeit - User Interface	Komplexe Bedienung der Technologie
		Überforderung	Komplexität der Technologie zu umfangreich
	Furcht	Angst ersetzt zu werden	Angst, durch die Technologie den Arbeitsplatz zu verlieren
		Kontrollverlust	Befürchtung, die Kontrolle über Daten zu verlieren
Organisati- onsebene	Fehlende Ressour- cen		Geplantes Management von Verände- rungsprozessen von einem Ausgangs- zustand zu einem Zielzustand
	Silodenken		Fehlende Ressourcen in Schlüsselpositionen sowie finanzielle Ressourcen
	Mehrere Produkte im Einsatz		Starkes Abteilungsdenken und -handeln; Mangel an grenzüberschreitender Zu- sammenarbeit
	Personalfluktuation		Unübersichtlichkeit für Mitarbeiter durch die Implementierung mehrerer Lösungen
	IT-Abteilung		Wissenslücken durch Verlust von ele- mentaren Wissensträgern
	Datenqualität		Aversion gegen die Einführung und Pflege neuer Technologien
Daten- ebene	Datenzugriff		Mangelnde Datenqualität als Hemmnis für die volle Nutzung der Technologien
	Performance		Zugang zu Daten als Hindernis für die volle Nutzung der Technologien
Metaebene	MangeInde Betreu- ung/Einbindung		Mangelnde Systemleistung (in Bezug auf Geschwindigkeit und Korrektheit) als Hindernis für die volle Nutzung der Technologien
	Vorgabe zur Nut- zung		Unzureichende Unterstützung und Einbindung der Anwender
	Sich verändernde Anforderungen		Druck des Managements, die Technologie zu nutzen
	Fehlender Problem- Solution Fit		Unzureichende Anpassung des Systems an neue Benutzerbedürfnisse als Hin- dernis für die volle Nutzung der Techno- logien
	Fehlende Ressour- cen		Technologien nicht für alle Probleme nutzbar

# 2.1.3 Einsatzgebiet-Akzeptanz-Matrix

Die Ergebnisse wurden abschließend in eine Einsatzgebiet-Akzeptanz-Matrix überführt. Hierbei wurde sowohl der erhobene Umfang des BA-Einsatzes, als auch die Akzeptanz der BA-Ergebnisse strukturiert aufgearbeitet. Hierfür wurde der Umfang des Einsatzes und die Akzeptanz der BA-Ergebnisse in einem Quantil-Split in hoch, mittel und niedrig unterteilt. Es zeigt sich, dass insbesondere die Bereiche HR und Service nur einen niedrigen Einsatzumfang und Akzeptanz vorweisen, während die Bereiche Logistik und Marketing/Vertrieb einen hohen Einsatzumfang und Akzeptanz vorweisen.

Tabelle 4: Einsatzgebiete-Akzeptanz-Matrix

Einsatzge- biet	Beispielhafte Anwendungen	Umfang des Ein- satzes	Akzep- tanz der BA Er- gebnisse	Ausgewählte Gründe für Nichteinsatz von BA / für Nicht-Akzeptanz von BA- Ergebnissen
Logistik	Erfassung und Analyse von Tourstopzahlen, Tourzeiten, Spritverbrauch, Reifenver- schleiß, Reparaturkosten, Ge- bietskennzahlen, Lieferkosten	Hoch	Hoch	Fehlende Software, Freigabe, Kosten
Produktion	Produktivitäts- und Quali- tätsüberwachung	Hoch	Mittel	Erfahrung wird höher gewichtet
Marke- ting/Vertrieb	Gebietsauswertungen, Kundenanalyse, Auftragsbewertung, Upselling, Crossselling, Budgetplanung, Prozessanalyse	Hoch	Hoch	Fehlende Expertise
Service	Reklamtionsanalyse, Anruf- auswertung, ID Bewertung, Auftragsabwicklung, Pro- zessanalyse	Niedrig	Niedrig	Bei Service geht es um ma- nuelle Aufträge (z. B. War- tung), kein Use Case
Infrastruktur	Erfassung und Analyse von Serverauslastung, Daten- durchsatz	Mittel	Mittel	Zu klein, Kosten zu hoch
HR	Personnel Expense Monitoring	Niedrig	Niedrig	Sehr schwierig, wegen Datenschutz in der HR Daten zu erheben und auszuwerten
R&D	Steuerung des R&D Ratios	Mittel	Mittel	Von automatischer Auswertung von Lebensläufen oder Ähnlichem halten wir nichts
Einkauf	ABC Analyse der Artikel und Bestände, Auswertung der Lieferanten, Bewertung von Lieferkosten, erfassungskenn- zahlen der Mitarbeiter	Mittel	Mittel	Altmodische Prozesse, feh- lender Drang der Führungs- ebene zur Durchsetzung von BA Tools

# 2.1.4 Fazit zu Arbeitspaket 1

Im ersten Arbeitspaket wurden im Rahmen einer Online-Umfrage Entscheidungsträger und Anwender von BA hinsichtlich des Umfangs des BA Einsatzes und der Akzeptanz von BA Ergebnissen befragt. Zudem wurden Anbieter von BA-Systemen bezüglich ihrer Einschätzung befragt. Die Ergebnisse dienen als Basis für den weiteren Projektverlauf, der auf die Erarbeitung und Validierung von akzeptanzsteigernden Maßnahmen abzielt.

# 2.2 Arbeitspaket 2

Das Arbeitspaket 2 "Einflussfaktoren auf die Akzeptanz von Business Analytics" diente der Entwicklung eines Modells zur Identifikation und Kategorisierung der Faktoren, die die Akzeptanz der durch BA gewonnenen Erkenntnisse beeinflussen.

Durchgeführte Arbeiten	Erzielte Ergebnisse
Systematische Literaturrecherche zur Identifikation und Kategorisierung der Einflussfaktoren auf das Akzeptanzsubjekt (Entscheidungsträger).	<ul> <li>Identifikation von Einflussfaktoren auf die Akzeptanz von durch BA gewonnenen Ergebnissen im Rahmen einer systematischen Literaturanalyse.</li> <li>Ableitung eines Akzeptanzmodells aus 57 Einflussfaktoren in zehn Clustern, die (a) die Akzeptanz durch Entscheidungsträger/Manager von datengetriebenen Ergebnissen beeinflussen, (b) bedingen ob im Unternehmen Wissen aus Daten generiert werden kann und (c) dass BA-Systeme akzeptiert werden.</li> </ul>
Tiefeninterviews und Workshops zur Validierung des Akzeptanzmodells (bzw. der Einflussfaktoren) hinsichtlich der Handlungsakzeptanz der Entscheidungsträger in Bezug auf technische und soziale Aspekte.	<ul> <li>Validierung des Akzeptanzmodells inklusive der darin enthaltenen Ein- flussfaktoren im Rahmen von Ex- pertengesprächen, einem Exper- ten-Workshop und einer quantitati- ven Befragung von 51 Anwendern.</li> </ul>
Experiment zur Ermittlung der Akzeptanz von Entscheidungsträgern im Hinblick auf ermittelte Akzeptanzfaktoren.	<ul> <li>Aufgrund der aktuellen Entwicklungen rund um Covid19 wurde die Durchführung des Experiments nicht im Labor, sondern über Amazon Mturk durchgeführt.</li> <li>Hierbei wurde die Akzeptanz von Algorithmen in der Mitarbeiterbewertung fokussiert.</li> </ul>

Eine der größten Herausforderungen bei der Einführung von BI&A-Systemen ist die Schaffung individueller Akzeptanz bei deren Nutzern (Ain et al. 2019). Allgemeine Modelle und Theorien wie das Technologieakzeptanzmodell (TAM) beschreiben, warum Individuen eine Technologie nutzen oder nicht nutzen (Davis 1986). Diese Modelle beschreiben jedoch nur im Allgemeinen, warum Individuen eine Technologie akzeptieren. Im Falle des TAM begründet sich die Akzeptanz von Systemen bspw. ausschließlich aus zwei Faktoren: Einerseits aus der wahrgenommenen Benutzerfreundlichkeit und andererseits aus der wahrgenommenen Nützlichkeit eines Systems (Davis 1986). Spezifische Modelle und Theorien, die einen umfassenden Katalog der Faktoren, die

für die Akzeptanz von Erkenntnissen aus BI&A für die Entscheidungsfindung umfassen und damit bewerten können, finden sich nicht in der Literatur (Ain et al. 2019). Vor diesem Hintergrund wurde in Arbeitspaket 2 ein Modell zur Identifikation und Kategorisierung der Faktoren, die die Akzeptanz der durch BA gewonnenen Erkenntnisse beeinflussen, entwickelt und validiert. Zudem wurde die Akzeptanz eines konkreten Anwendungsfalls, nämlich dem der Black Box-Algorithmen, experimentell getestet.

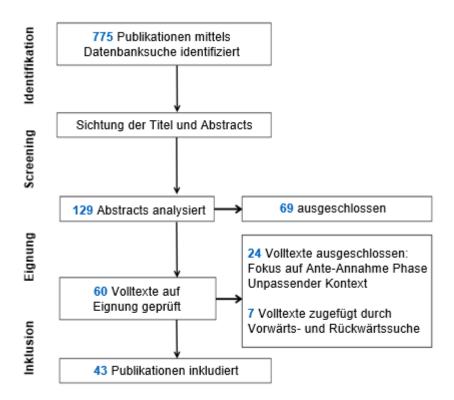
# 2.2.1 Einflussfaktoren auf das Akzeptanzsubjekt und Akzeptanzmodell

# Systematische Literaturrecherche

Zur Entwicklung des Modells wurde zunächst ein systematisches Literaturreview nach Webster und Watson (2002) einerseits hinsichtlich Faktoren für die Akzeptanz der durch BI&A generierten Erkenntnisse und anderseits für die Akzeptanz von BI&A-Systemen durch Entscheidungsträger bzw. Manager durchgeführt. Theoretischer Fokus lag entsprechend auf der Post-Annahme-Phase von BI&A. Zur Ermittlung der zu analysierenden Publikationen wurden neun führende Datenbanken und Suchmaschinen, die Zeitschriften aus den Bereichen Informatik, Wirtschaftsinformatik, Wirtschaftswissenschaften und Sozialwissenschaften abdecken, systematisch durchsucht: Web of Science, ScienceDirect, Scopus, ECONbiz, AIS eLibrary, ACM Digital Library, ProQuest, ESBCO Business Source Complete und IEEE Xplore. Die dabei verwendeten Suchbegriffe wurden zu Beginn des Suchprozesses vor dem Hintergrund des Forschungsziels, der Ermittlung von Faktoren für die Akzeptanz von BI&A-Erkenntnissen und -Systemen, definiert und anschließend in verschiedene Suchterme überführt: "BA", "business intelligence", "big data analytics", "decision support systems", "evidence based management", "data science". Die Suchterme wurden jeweils mit den folgenden Suchtermen kombiniert: "user acceptance", "managerial acceptance", "data driven decision making", "data driven decisions", "data science results", "acceptance".

Zur Auswahl der Publikationen wurden vor der Suche In- und Exklusionskriterien definiert, die sich teilweise auch in den Suchtermen widerspiegeln. Aufgenommen wurden ausschließlich vollständige quantitativ- und qualitativ-empirische peer-reviewed Journal- und Konferenzbeiträge die die Suchbegriffe in Titel, Abstract oder Keywords führen. Ausgeschlossen wurden Studien, die thematisch nicht im Managementbereich liegen, z. B. Arbeiten über klinische Entscheidungsunterstützungssysteme. Außerdem wurden Bücher, Buchkapitel und andere nicht referenzierte Publikationen wie Berichte, die sich an Führungskräfte richten, ausgeschlossen. Auch Publikationen mit einem starken Technikfokus (z. B. die die technische Entwicklung von Algorithmen beschreiben) wurden ausgeschlossen. Es wurden ausschließlich Beiträge aus Zeitschriften aufgenommen, die mindestens eine C-Bewertung im VHB-JOURQUAL3 erhalten haben, aufgenommen. Falls keine Bewertung im VHB-JOURQUAL3 für die entsprechende Zeitschrift zur Verfügung stand, wurden die Beiträge nur bei starker thematischer Deckung aufgenommen. In Bezug auf den Veröffentlichungszeitraum wurden nur Studien berücksichtigt, die in der Zeit von 2000 bis 2019 veröffentlicht wurden. Dieser Zeitraum wurde gewählt, da BI&A in der Literatur zum ersten Mal im Jahr 2000 Beachtung fand (Chen et al. 2012). Eine Ausnahme wurde für eine 1995 veröffentlichte und vielzitierte Studie über den Einfluss von Erklärungen im Rahmen entscheidungsunterstützender Systeme auf die Akzeptanz datengetriebener Erkenntnisse gemacht (Ye und Johnson 1995). Es wurden ausschließlich Publikationen in deutscher und englischer Sprache untersucht.

In der automatisierten Datenbanksuche konnten zunächst 775 Publikationen identifiziert werden, die die Suchbegriffe in Titel, Abstract oder Keywords führen. Diese Publikationen dienten als Basis für eine tiefgehende Analyse, bei der auf Basis unterschiedlicher Ausschusskriterien alle "relevanten" Publikationen herausgesucht wurden. Dieser Suchprozess ist in Abbildung 9 dargestellt. Final wurden 43 Publikationen ausgewählt.



#### **Abbildung 9: Suchprozess**

Unter den 43 analysierten Publikationen finden sich 33 quantitative Studien, die die Durchführung und Ergebnisse von Umfragen oder Experimenten beschreiben, fünf qualitative Studien, die die Durchführung und Ergebnisse von Experteninterviews und Case Studies beschreiben, sowie sechs mixed-method Studien, die sowohl quantitative als auch qualitative empirische Ansätze verfolgen. Die analysierten Publikationen wurden hauptsächlich in den letzten zehn Jahren publiziert. Vor 2010 finden sich nur sieben Publikationen, die für die Untersuchung als relevant erachtet wurden (vgl. Abbildung 10)

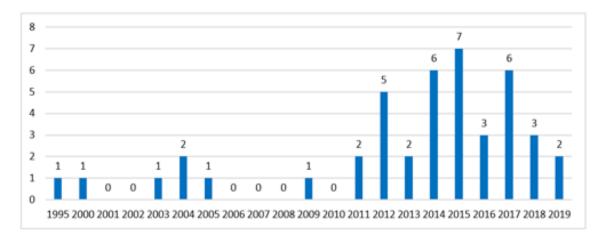


Abbildung 10: Publikationen nach Jahren

Der Großteil der analysierten Studien befragte Fach- oder Führungskräfte und nur ein Viertel konzentrierte sich auf Fach- oder Hochschulpersonal oder Studenten. Bei den Studien, in die auch Studenten einbezogen wurden, handelte es sich durchweg um experimentelle Studien, in denen reale Geschäftsaufgaben simuliert wurden, die Entscheidungen im Zusammenhang mit Geschäftsproblemen beinhalteten. Der Mittelwert der Stichprobengrößen der quantitativen Studien passend zum Untersuchungsgegenstand beträgt 184,60. In den Studien wurden eine Vielzahl von Kontexten untersucht, darunter Fertigung, Telekommunikation, Marketing, Finanzen, Informationstechnologie, Logistik und Regierungsorganisationen. Die in den Studien beschriebenen Anwendungsfälle umfassen sowohl den Einsatz von dezidierten BI&A-Systemen, als auch den Einsatz von Standard-Analysesoftware und die Analyse großer Datenmengen.

In der Tiefenanalyse der aufgefundenen Publikationen konnten 57 Faktoren identifiziert werden, die die Akzeptanz von Entscheidungsträgern/Managern gegenüber datengetriebener Ergebnisse oder BI&A-Systeme beeinflussen. Die Einflussfaktoren umfassen bspw. die Güte der BI&A-Systemen zu Grunde liegenden Daten, die analytischen Fähigkeiten des Entscheidungsträgers und die visuelle Präsentation der Ergebnisse. Die aufgefundenen Einflussfaktoren wurden anschließend bezogen auf den Akzeptanzkontext in zehn Kategorien kodiert. Die Kategorien umfassen einerseits Faktoren in Bezug auf die Qualität der für die Erstellung der Ergebnisse genutzten Daten und Datenanbieter sowie Faktoren in Bezug auf die Fähigkeiten der mit Analysen betrauten Mitarbeiter (z.B. Analysten, Data Scientists) wie deren Fähigkeiten Big Data Analysen durchzuführen. Weiterhin wird der Faktor Unternehmensgröße benannt. Darüber hinaus beschreibt ein Faktor, ob mit den Ergebnissen eine Erklärung, bspw. zur Rechtfertigung der Ergebnisse, bereitgestellt wird. Weitere Faktoren beschäftigen sich mit der Zusammenstellung des mit den Analysen betrauten Teams bspw. in Bezug auf die Zusammensetzung aus Domänenspezialisten und Analytikern.

Des Weiteren bezieht sich ein Faktor auf die Charakteristiken der Entscheidungsaufgabe insbesondere im Hinblick auf die wahrgenommene Schwierigkeit der Aufgabe. Mehrere Faktoren beziehen sich außerdem auf die Charakteristiken des Entscheidungsträgers, bspw. im Hinblick auf dessen analytische Fähigkeiten, Rationalität oder

Leistungserwartung. Zusätzlich beziehen sich mehrere Faktoren auf die Präsentation der Ergebnisse, bspw. ob diese anpassbar sind oder ob paarweise Vergleiche zwischen Alternativen geboten werden. Darüber hinaus beschäftigen sich einige Faktoren mit den Charakteristiken des BI&A-Systems. Hierunter fällt bspw. die wahrgenommene Nützlichkeit des Systems, aber auch ob Nutzerbedürfnisse vollumfänglich abgebildet werden. Abschließend beziehen sich einige Faktoren auf organisationale Gesichtspunkte wie die BA-Kultur des Unternehmens. Eine Übersicht über die 57 Einflussfaktoren und ihre Kategorisierung findet sich in Tabelle 5.

Tabelle 5: Akzeptanz-Einflussfaktoren

Kategorie	Faktor in der Literatur	Akzeptanz von Erkenntnissen	Akzeptanz von (BI&A)-Systemen
	Data quality of the source Assurance of data quality at source	Janssen et al. 2017 Kowalczyk und Bux- mann 2015 Merendino et al. 2018	Shin 2003 Bischoff et al. 2015 Puklavec et al. 2018 Jaklič et al. 2018
	Contractual and relational governance of data provider	Janssen et al. 2017	Gaillio ot all 2010
Datenqualität	Collaboration and knowledge exchange between entities	Janssen et al. 2017	
Datenquamat	Process integration and standardization	Janssen et al. 2017	
	Standardization of data source access	Kowalczyk & Buxmann 2015	
	Explicit differentiation and modeling of qualitative and quantitative aspects	Merendino et al. 2018 Kowalczyk & Buxmann 2015	
Fähigkeiten der mit	Big Data Analytics capabilities of staff	Janssen et al. 2017	Grublješič und Jaklič 2015
Analysen betrauten Mitarbeiter (z.B.	Specialists in Big Data Analytics in organization	Janssen et al. 2017	
Analysten Data Scientists)	Shortfall in cognitive capability Analysts' interaction skills	Merendino et al. 2018 Thirathon et al. 2018	
	Allalysis litteraction skills	Gürdür et al. 2019	
Unternehmensgröße	Small firm size	Thirathon et al. 2017	
Bereitgestellte Erklärung	Justification Trace or line of reasoning	Ye und Johnson 1995	
	Composition of analytic team of	Kowalczyk und Bux-	
Zusammenstellung	domain specialists and analytics	mann 2015	
der mit Analysen	specialists	Merendino et al. 2018	
betrauten Teams	Institutionalization of an analytic integrator	Kowalczyk und Bux- mann 2015	
Charakteristiken der Entscheidungsauf- gabe	Perceived task difficulty	Parkes 2012	
	Experience of decision maker	Janssen et al. 2017 Nah und Benbasat 2004	
Charakteristiken des Entscheidungs-	Analytic skills of decision maker	Janssen et al. 2017 Thirathon et al. 2018	
trägers	Rationality of decision maker	Kowalczyk & Buxmann 2015	
	Skeptical about BI&A reports	Namvar et al. 2016	

Kategorie	Faktor in der Literatur	Akzeptanz von Erkenntnissen	Akzeptanz von (BI&A)-Systemen
	Fear of losing their independence	Merendino et al. 2018	
	Cognitive biases	Merendino et al. 2018	
	Cognitive overload	Merendino et al. 2018	
	Habit to use	Han et al. 2016	
	Satisfaction with system	Han et al. 2016	Hou 2012, 2016
	Increased effort and guidance of the decision maker	Kayande et al. 2009	
	Behavioral intention to use Decision Support System / BI		Dulcic et al. 2012; Hou 2012; Hou 2014; Kohnke et al. 2011
	Perceived behavioral control Computer anxiety		Hou 2012 Hou 2014
	Performance expectancy		Hou 2014 Jaklič et al. 2018
	Explicit tradeoff judgments / Pairwise comparisons between alterations	Aloysius et al. 2006	Janiic et al. 2010
	natives Absolute measurements for decision maker	Aloysius et al. 2006	
Präsentation der Er-	Adaptability	Gettinger et al. 2013	
gebnisse	Reduction of alternatives	Kowalczyk and Bux- mann 2015	
	Semi formalized problem specification	Kowalczyk and Bux- mann 2015	
	Result demonstrability		Jaklič et al. 2018 (Grublješič et al. 2019)
			Dulcic et al. 2012
	Perceived usefulness of the sys-	Parkes 2012	Bischoff et al. 2015
	tem	Han et al. 2016	Kohnke et al. 2011 Hou 2016
			Jaklič et al. 2018
	Suggestive decisional guidance	Parkes 2012	Jakiic et al. 2010
	Correctness of Decision Support		Hou 2012
	System insights	Brauner et al. 2019	Jaklič et al. 2018
	Perceived ease of use to create		
	Perceived ease of use to create reports		
Charakterstiken des			Shin 2003
Charakterstiken des BI&A-Systems			Shin 2003 Hou 2012
	reports		Shin 2003
			Shin 2003 Hou 2012 Elbeltagi et al. 2005
	reports		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012
	reports		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012
	reports		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018
	reports		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003
	reports  Perceived ease of use		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003 Kohnke et al. 2011
	reports  Perceived ease of use		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003 Kohnke et al. 2011 Bischoff et al. 2015
	reports  Perceived ease of use  System performance  Coverage of user requirements		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003 Kohnke et al. 2011 Bischoff et al. 2015 Kohnke et al. 2011
	reports  Perceived ease of use  System performance  Coverage of user requirements  Adaptability and controllability	Thirathon et al. 2017	Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003 Kohnke et al. 2011 Bischoff et al. 2015
	reports  Perceived ease of use  System performance  Coverage of user requirements	Thirathon et al. 2017 Namvar et al. 2016	Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003 Kohnke et al. 2011 Bischoff et al. 2015 Kohnke et al. 2011
	reports  Perceived ease of use  System performance  Coverage of user requirements  Adaptability and controllability  Big Data Analytics sophistication		Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003 Kohnke et al. 2011 Bischoff et al. 2015 Kohnke et al. 2011
BI&A-Systems	Perceived ease of use  System performance  Coverage of user requirements  Adaptability and controllability  Big Data Analytics sophistication  Commitment in BI environment	Namvar et al. 2016	Shin 2003 Hou 2012 Elbeltagi et al. 2005 Dulcic et al. 2012 Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Jaklič et al. 2018 Shin 2003 Kohnke et al. 2011 Bischoff et al. 2015 Kohnke et al. 2011

Kategorie	Faktor in der Literatur	Akzeptanz von Erkenntnissen	Akzeptanz von (BI&A)-Systemen
		Gürdür et al. 2019 Thirathon et al. 2017	
	Change in decision-making approach / Change in job content		Jiang et al. 2000
	Influence of Peers		Grublješič & Jaklič 2015 Hou 2014b Bischoff et al. 2015
	illiliderice of Peers		Hou 2014a Jaklič et al. 2018 Grublješič et al. 2019 Grublješič & Jaklič 2015
	User support like user-training		Duan et al. 2012 Bischoff et al. 2015 Kohnke et al. 2011 Elbeltagi et al. 2005 Grublješič & Jaklič
	Top management support		2015 Bischoff et al. 2015 Puklavec et al. 2018 Kohnke et al. 2011
	Organizational compatibility of technology		Jaklič et al. 2018
	Ability to locate data		Shin 2003
	User participation in implementation of the system		Grublješič and Jaklič 2015
	Clearly defined responsibilities		Grublješič and Jaklič 2015

# Akzeptanzmodell

Die kategorisierten Einflussfaktoren wurden anschließend in ein Akzeptanzmodell überführt. Das Akzeptanzmodell beschreibt den Zusammenhang der Faktoren Entscheidung, Mensch, Organisation und Prozess auf die Akzeptanz des Entscheidungsträgers (vgl. Abbildung 11). Die Kategorie Entscheidung bezieht sich vor diesem Hintergrund auf alle Faktoren, die sich auf die Charakteristiken der Entscheidungsaufgabe als auch auf die des Entscheidungsträgers beziehen. Die Kategorie Mensch bezieht sich auf die Zusammenstellung der mit Analysen betrauten Teams als auch die Fähigkeiten der mit Analysen betrauten Mitarbeiter. Die Kategorie Organisation bezieht sich auf organisationale Faktoren wie bspw. die Unternehmenskultur als auch die Unternehmensgröße. Die Kategorie Prozess bezieht sich auf die Datenqualität, die Charakteristiken des Bl&A-Systems, ob und in welcher Form Erklärungen bereitgestellt werden sowie auf die Präsentation der Ergebnisse.

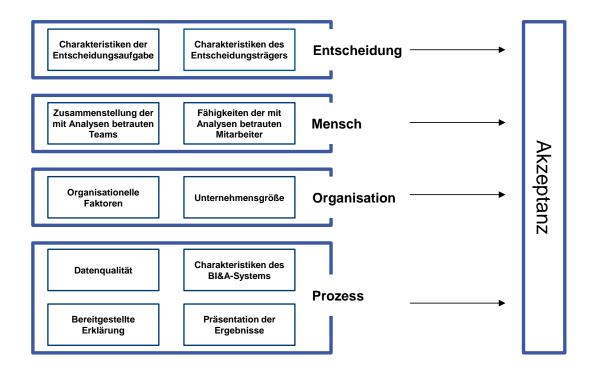


Abbildung 11: Modell Akzeptanzfaktoren

Das Akzeptanzmodell wurde im Rahmen eines Workshops mit dem projektbegleitenden Ausschuss validiert. Hierfür wurde zunächst seitens der Mitarbeiter der Forschungsstellen ein kurzer Überblick über die Ergebnisse der systematischen Literaturanalyse bzw. der 57 Einflussfaktoren und zehn Kategorien gegeben. Anschließend wurden das daraus abgeleitete Modell und die vier Kategorien Entscheidung, Mensch, Organisation und Prozess gemeinsam besprochen. Die Workshopteilnehmer schätzten die Charakteristik der Entscheidungsaufgabe als wesentlichen Faktor für die Akzeptanz durch den Entscheider ein. Handelt es sich um eine Entscheidungsaufgabe, die eine subjektive Einschätzung umfasst oder erfahrungsbasierte Annahmen erfordert (z. B. wegen fehlenden Daten), vermuten die Teilnehmer eine geringe Akzeptanz. Zudem wurde angemerkt, dass sich die Charakteristika von Entscheidungsaufgaben je nach Berufsumfeld stark unterscheiden können. Als wichtiger weiterer Einflussfaktor auf Seiten der Organisation wurde der Führungsstil von Unternehmen genannt.

Generell wurde das Akzeptanzmodell von den Teilnehmern als umfassend befunden. Der direkte Praxisnutzen des Modells erschloss sich einigen Teilnehmern wegen des konzeptionellen und umfassenden Charakters des Modells nicht. Allerdings stieß gerade die detaillierte Aufstellung (vgl. Tabelle 5) auf Interesse der PA-Mitglieder. Ein Unternehmensvertreter kündigte bspw. an die Übersicht mit den 57 Einzelfaktoren als Checkliste in den Methodenkasten für Einführungsprojekte von BA-Lösungen bei Kunden zu übernehmen.

# 2.2.2 Validierung des Akzeptanzmodells

Weiterhin wurde das Akzeptanzmodell im Rahmen der Online-Befragung (siehe auch AP1) validiert. Hierfür wurden die 51 Umfrageteilnehmer dazu aufgefordert die Relevanz der einzelnen Kategorien für die Akzeptanz von datengetriebenen Ergebnissen einzuschätzen.

Im zweiten Teil des Fragebogens wurden die Einflussfaktoren des in Arbeitspaket 2 entwickelten Modells der Einflussfaktoren auf die Akzeptanz von BA hinsichtlich der Relevanz der einzelnen Unterkategorien bewertet. Den Umfrageteilnehmern wurde dazu zunächst beschrieben, wie das Modell entwickelt wurde (vgl. Abbildung 12 und Abbildung 13). Zusätzlich gab es für die Teilnehmer die Möglichkeit, ein PDF Dokument mit der detaillierten Darstellung des Vorgehens aufzurufen. Zur Bewertung der Relevanz standen den Teilnehmern fünf Antwortmöglichkeiten (gar nicht relevant, wenig relevant, mittelmäßig relevant, häufig relevant, sehr häufig relevant) zur Verfügung.

#### Teil 2: Akzeptanzfaktoren

Eine systematische Literaturrecherche hat insgesamt 68 Einflussfaktoren für die Akzeptanz von durch BA gewonnenen Ergebnissen durch Entscheidungsträger ergeben. Diese lassen sich in 4 Überkategorien (Entscheidung, Mensch, Organisation und Prozess) mit insgesamt 10 Unterkategorien gruppieren. Hier finden Sie weitere Informationen zur durchgeführten systematischen Literaturrecherche.

	Gar nicht relevant	Kaum relevant	Mittel relevant	Ziemlich relevant	Sehr relevant
Charakteristiken der Entscheidungsaufgabe (Schwierigkeit / Tragweite der Entscheidung)	0	0	0	0	0
Charakteristiken des Entscheidungsträgers (u.a. Erfahrung, analytische Fähigkeiten, Einstellung gegenüber BA Lösungen, Überforderungen, Zeitmangel bei der Ergebnisinterpretation)	0	0	0	0	0
fensch: Wie relevant schätzen Sie die f	olgenden Faktore	n für die Akzep	otanz von BA-E	Ergebnissen ein?	
1ensch: Wie relevant schätzen Sie die f	olgenden Faktore Gar nicht relevant		otanz von BA-E Mittel relevant	Ergebnissen ein? Ziemlich relevant	Sehr relevant
lensch: Wie relevant schätzen Sie die fo Zusammenstellung der mit Analysen betrauten Geams (z.B. Kombination von Domain- und Analyticsexperten)					

Abbildung 12: Fragenbogenstudie - Validierung des Akzeptanzmodells (Teil 1)

	Gar nicht relevant	Kaum relevant	Mittel relevant	Ziemlich relevant	Sehr relevant
Organisationelle Faktoren (u.a. Unterstützung durch Management, Kollegen, Definition von von Verantwortlichkeiten)	0	0	0	0	0
Unternehmensgröße (z.B. Start-up, Mittelständischen Unternehmen; Konzern)	0	0	0	0	0
Prozess: Wie relevant schätzen Sie die fo	olgenden Faktore	en für die Akzep	ptanz von BA-l	Ergebnissen ein?	
	Gar nicht relevant	Varies salarest			
	Our frienc relevant	Kaum reievant	Mittel relevant	Ziemlich relevant	Sehr relevant
Datenqualität (z.B. Qualität der Quelle, Standardisierung des BA Prozess oder der Datenbereitstellung)	0	O O	Mittel relevant	Ziemlich relevant	Sehr relevant
Standardisierung des BA Prozess oder der	_				
Standardisierung des BA Prozess oder der Datenbereitstellung) Charakteristiken des BA Systems (z.B.	0	0	0	0	0

Abbildung 13: Fragenbogenstudie – Validierung des Akzeptanzmodells (Teil 2)

Bei der Auswertung zeigt sich, dass die wichtigsten Faktoren zumeist im Bereich des zugrundeliegenden Prozesses aufzufinden sind. So beziehen sich die drei relevantesten Kategorien auf den Prozess (Datenqualität Präsentation der Ergebnisse Charakteristiken des BI&A-Systems). Die Unternehmensgröße wird mit einem relativ großen Abstand als am wenigsten relevant eingeschätzt. Zudem nimmt die Zusammenstellung des Teams im Gegensatz zu den Fähigkeiten des mit den Analysen betrauten Mitarbeiters nur eine untergeordnete Rolle in Bezug auf die Akzeptanz datengetriebener Ergebnisse ein. Im Gegensatz zum Validierungsworkshop wird die Charakteristik der Entscheidungsaufgabe als weniger relevant eingeschätzt. Eine Ursache für die Diskrepanz könnte im Ablauf der Online-Befragung liegen. Hier wurden die Teilnehmer vor der Bewertung der Akzeptanzfaktoren zunächst aufgefordert, die Bereiche, in denen ihre fachliche Expertise liegt, anzugeben und BA-Anwendungen aus diesen Bereichen zu nennen. Hierbei kann es zu einer Verzerrung der Einschätzung des Teilnehmers kommen, da in erster Linie BA-Systeme aus dem eigenen Fachbereich in den Sinn kommen.

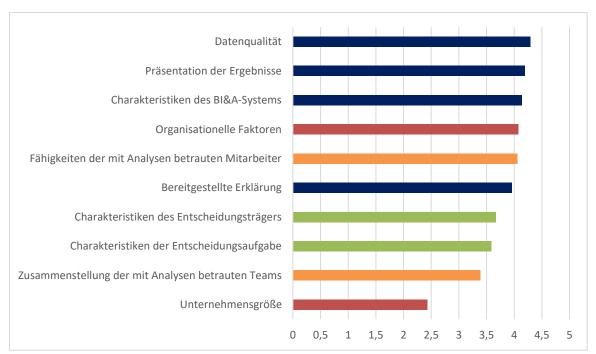


Abbildung 14: Relevanz der Faktoren im Akzeptanzmodell

Aufgrund der hohen wissenschaftlichen Aktualität und Relevanz des Themas "Black Box Algorithmen" wird nachfolgend einer der Akzeptanzfaktoren exemplarisch im Rahmen eines Experiments tiefgehend analysiert. Ziel ist dabei die Ermittlung der Akzeptanz von Entscheidungsträgern in einen speziellen Anwendungsfall – nämlich die Akzeptanz von Algorithmen in der Mitarbeiterbewertung, wenn der Algorithmus dem Entscheidungsträger zuvor nicht erklärt wird. Dies entspricht dem Akzeptanzfaktor "Bereitgestellte Erklärung" in Abbildung 14. Die Mitarbeiterbewertung ist eine der Hauptaufgaben von Managern, weshalb dieses Thema hier speziell fokussiert wird.

# 2.2.3 Experiment zur Ermittlung der Akzeptanz von Algorithmen bei Entscheidungsträgern (Akzeptanzfaktor "Bereitgestellte Erklärung")

Nachdem im vorangegangen Abschnitt verschiedene Einflussfaktoren quantitativ von Praktikern bewertet wurden, wird im Folgenden dargestellt, wie die Akzeptanz von Black Box-Algorithmen empirisch in einem Online-Experiment untersucht wurde. Dies entspricht einer tiefgehenden Analyse des Akzeptanzfaktors "Bereitgestellte Erklärung" in einen speziellen Anwendungsfall in der Mitarbeiterbewertung, in welchem der Algorithmus dem Entscheidungsträger zuvor nicht erklärt wird. Im Rahmen der Diskussionen im Projektausschuss hat sich gezeigt, dass dieser Aspekt eine besondere Relevanz für Manager hat, da die Verwendung von Black Box-Algorithmen und die Bereitstellung von Erklärungen zwei wesentliche Stellhebel sind. Zudem ist die Mitarbeiterbewertung eine der Hauptaufgaben von Managern, weshalb der Anwendungsfall vom Projektausschuss als besonders relevant erachtet wird. Das Vorgehen und die Ergebnisse der beiden Experimente werden in einem Artikel dargestellt, der bei der Fachzeitschrift European Accounting Review für die Sonderausgabe "Innovative Data

Sources in Management Accounting Research and Practice" zum 1. März 2021 eingereicht wurde.

Eine Möglichkeit, Black Box-Algorithmen im Unternehmenskontext zu etablieren, ist es, diese im Rahmen der Mitarbeiterbewertung von Mitarbeitern einzusetzen. Dabei ergänzen oder ersetzen sie die in der Mitarbeiterbewertung üblichen subjektiven und objektiven Maße. Für viele Organisationen sind objektive und subjektive Maße gängige Instrumente der Leistungsbewertung (Kaplan und Norton 1996; Ittner, C. D. and D. F. Larcker 1998; Ittner et al. 2003; van der Stede et al. 2006; Luft 2009). Frühere Forschungsarbeiten konzentrierten sich auf Verzerrungen in der Leistungsbewertung (z. B. Prendergast und Topel 1993; Moers 2005; Bol 2010; Golman und Bhatia 2012; Bol et al. 2016) und unterschiedliche Wahrnehmungen zwischen objektiven und subjektiven Messungen (z. B. Hoffman et al. 1991; Rajan und Reichelstein 2009; Kunz 2015; Dai et al. 2018). Ein bisher weitgehend unerforschtes Thema ist der Einsatz von Algorithmen in der Mitarbeiterbewertung, obwohl die Anwendbarkeit nachgewiesen ist. Bspw. können Black Box Algorithmen zur Bewertung von Emotionen in Sprache und Höflichkeit von Mitarbeitern in Callcentern eingesetzt werden (Petrushin 1999; Azadeh et al. 2013). Mit dem Aufkommen immer leistungsfähigerer Algorithmen die immer mehr Daten verarbeiten und sogar menschliche Fähigkeiten imitieren können (Castelo 2019; Badillo et al. 2020), wurden Algorithmen entwickelt, die in der Lage sind, Mitarbeiterbewertung durchzuführen und die Möglichkeit bieten diese als Ersatz für subjektive Messungen zu verwenden. Im Vergleich objektiver und subjektiven Maße neigen Manager dazu objektiven Maßen mehr Gewicht beizumessen (Hsee et al. 2003; Tsai und Hsee 2009; Dai et al. 2018).

Mitarbeiterbewertung wird als eine periodische Bewertung der Leistung eines Mitarbeiters anhand bestimmter Erwartungen definiert. Der Prozess beinhaltet die Messung und Bewertung der Leistung von Mitarbeitern anhand festgelegter Ziele (Ahmad und Azman Ali 2004; Abu-Doleh und Weir 2007).

#### Methodik

Im Forschungsprojekt wurden zwei Experimente über Amazon Mechanical Turk (MTurk) durchgeführt. MTurk ist ein zunehmend beliebtes Crowdsourcing-Instrument u. a. zur Rekrutierung von Teilnehmern für wissenschaftliche Studien einschließlich der Accounting Forschung (Buchheit et al. 2018; Bentley 2020). Die Experimente wurden von Dezember 2020 bis Februar 2021 durchgeführt. Die Teilnehmer wurden auf MTurk Worker beschränkt, die sich als Manager auf der Plattform eingetragen haben, damit konsistente Ergebnisse generiert werden. Weiterhin wurden Teilnehmer davon abgehalten, an beiden Experimenten teilzunehmen. Insgesamt haben in beiden Experimenten 1.267 Personen teilgenommen, davon haben 525 Personen den Attention Check bestanden (311 in Experiment 1 und 214 in Experiment 2).

In beiden Experimenten übernahmen die Teilnehmer die Rolle eines regionalen Personaldirektors des fiktiven Unternehmens *PharmaCo*, einem Großhändler für Arzneimittel und medizinische Instrumente. Das strategische Ziel von PharmaCo ist die Maximierung des Betriebsgewinns.

Aufgabe der Teilnehmer war es, die Manager zweier Verteilungszentren (A und B) anhand von Maßen auf einer Skala von 0 bis 100 zu bewerten. Insgesamt wurden sechs Maße im Experiment verwendet. Davon waren zwei Maße objektiv (im Folgenden OM [objective measures]), zwei subjektiv (SM) und zwei ein Resultat von Black Box Algorithmen (BBI). Fünf dieser Maße wurden von Dai et al. (2018) übernommen, die für ein ähnliches Experiment bereits verifiziert hatten, dass diese Maße im Allgemeinen als gleich valide angesehen werden, um eine Übergewichtung einzelner Maße aufgrund unterschiedlicher Wahrnehmung zu verhindern. Darüber hinaus wurde in sieben Interviews mit Managern ein weiteres Maß identifiziert, das als gleich valide wie die fünf von Dai et al. (2018) übernommenen Maße wahrgenommen wurde. Den Teilnehmern wurde explizit kommuniziert, dass die Maße, die Ihnen für die Mitarbeiterbewertung zur Verfügung gestellt wurden, sich in der Vergangenheit als gleich sensitiv und gleich valide erwiesen haben.

In Experiment 1 wurden jedem Teilnehmer vier Maße zur Bewertung der Manager A und B zur Verfügung gestellt. Für jedes der vier angegebenen Maße erhielten die Teilnehmer eine Beschreibung der Maße, eine Datenquelle (d. h. wie die Maße bestimmt wurde), einen vom Unternehmen festgelegten Zielwert sowie die Bewertungen beider Manager A und B. Die Teilnehmer erhalten dabei je zwei BBI und je nach Gruppe zwei OM oder zwei SM. Innerhalb dieser Gruppen wurden die Maße so gewählt, dass ein Manager in beiden BBI oder in beiden OM bzw. SM besser abgeschnitten hat. Der Durchschnitt der Bewertungen aller vier Maße ist bei beiden Managern allerdings gleich. Abbildung 15 zeigt beispielhaft die Aufgabe einer Gruppe. Diese Gruppe hatte zwei OM und zwei BBI zur Verfügung, wobei Manager A in den BBI besser abgeschnitten hat, Manager B in den beiden OM. Eine Aversion der Manager lässt sich dann dadurch messen, dass Manager, der in den BBI besser Bewertungen hat, bei den Teilnehmern schlechter bewertet wird.

		Actual per	formance
Measures	Target for both Managers	Distribution Center A (Manager A)	Distribution Center B (Manager B)
Warehouse capability utilization (i.e. the percentage of warehouse capability used in operations) Source of data: Warehouse inspection records	82%	86.1%	90.6%
Equipment maintenance and adjustment (i.e. the percentage of warehousing and delivery equipment's timely maintenance as required by service standards and timely adjustment as needed by order processing)  Source of data: Equipment management records	86%	90.1%	94.6%
Employee ability enhancement (i.e. the effectiveness in increasing employees' work-related knowledge, skills and capabilities)  Source of data: Result of an innovative algorithm on a scale from 0 to 100, with 100 being the best performance	80	88	84
Innovation and improvement (i.e. the effectiveness in improving, optimizing, and innovating the current operating procedures)  Source of data: Result of an innovative algorithm on a scale from 0 to 100, with 100 being the best performance	85	94	89
Please rate the performance of both managers on a scale from 0-100, where 100 is the bes	st performand	ce.	
Manager A			
Manager B			

Abbildung 15: Beispielhaft Darstellung der Aufgabe in Experiment 1 (Gruppe BBI vs. OM)

Neben der Mitarbeiterbewertung wurde eine Reihe von Kontrollfragen gestellt, um Faktoren zu erheben, die das Resultat beeinflussen können (demographische Faktoren, Vertrautheit mit Algorithmen etc.). Außerdem wurde die Position der Maße innerhalb der Gruppen verändert, um auszuschließen, dass sich Teilnehmer bspw. an der Bewertung der oberen Maße orientieren, ohne die unteren zu beachten. Die Platzierung von Maßen haben allerdings keine signifikanten Einflüsse auf die Ergebnisse.

# **Ergebnisse**

Zunächst seien die Ergebnisse der Mitarbeiterbewertung der Teilnehmer der Gruppe BBI vs. OM bzw. SM sowie statistische Ausreißer diskutiert. Ausgeschlossen wurden dabei Teilnehmer, deren Ratings in Summe 100 ergaben oder die außerhalb einer 95% Ellipse lagen. Es wird vermutet, dass einige Teilnehmer bereits oft in Experimenten teilgenommen haben, in denen eine Gesamtpunktzahl zwischen zwei Managern aufgeteilt werden sollte, sodass sie die Gesamtbewertung von 100 auf beide Manager aufgeteilt haben. Diese haben ähnlich wie Ausreißer außerhalb einer 95 %-Ellipse um die Daten die Ergebnisse stark verzerrt, sodass sie ausgeschlossen werden mussten. Der Ausschluss gefährdet die externe Validität des Experiments nicht, da nicht vermutet wird, dass Ausreißer dieser Art in der Realität auftreten.

Betrachtet man die Durchschnittsbewertungen der Manager im Vergleich, lässt sich feststellen, ob BBI gleichwertig gewichtet wurden wie OM bzw. SM. In der Gruppe BBI vs. OM wurde der Manager, der in den BBI besser bewertet war, im Schnitt mit 89,40 bewertet, der Manager, der in den OM besser bewertet war, mit 89,34. Die Manager wurden also im Schnitt gleich bewertet.

Dabei wurde außerdem untersucht, ob dieser minimale Unterschied von 0,07 signifikant ist – das konnte erwartungsgemäß verneint werden. Analog dazu ist das Resultat der anderen Gruppe BBI vs. SM. Der Manager, der in den BBI besser bewertet war, wurde im Schnitt mit 89.95 und der Manager, der in den SM überlegen war, mit 89.68 bewertet. Auch dieser Unterschied von 0.27 ist nicht signifikant. Nach Experiment 1 kann also festgehalten werden, dass Algorithmen unter den im Experiment geschaffenen Voraussetzungen akzeptiert werden.

Um auszuschließen, dass dieses Resultat durch die unterschiedlichen Maße, die für BBI und OM bzw. SM genutzt wurden, generiert wurde, wurde ein zweites Experiment durchgeführt. In Experiment 2 hatte jeder Teilnehmer drei Maße zur Bewertung der Manager A und B zur Verfügung. Für jedes der drei angegebenen Maße erhielten die Teilnehmer eine Beschreibung der Maße, eine Datenquelle (d. h. wie die Maße bestimmt wurden), einen vom Unternehmen festgelegten Zielwert sowie die Bewertungen beider Manager A und B. Die Teilnehmer erhalten dabei je zwei OM und ein drittes Maß, das in jeder Gruppe gleich beschrieben wurde und die gleiche Bewertung hatte. Allerdings war hier die Datenquelle (BBI, OM oder SM) je nach Gruppe unterschiedlich. Das dritte Maß unterscheidet sich zwischen den Gruppen also nur in der Art des Maßes. Sollten im ersten Experiment überlagerte Effekte vorliegen, wie bspw. der Übergewichtung eines speziellen Maßes, kann dies durch das zweite Experiment ausgeschlossen werden. Abbildung 16 zeigt die Aufgabe der Gruppe OM, bei der das variable Maß, *Innovation and Improvement*, als objektiv beschrieben ist.

		Actual Pe	rformance
Measures	Target for both Managers	Distribution Center A (Manager A)	Distribution Center B (Manager B)
On-time delivery (i.e. the percentage of orders delivered within contractual time limit) Source of data: Company's internal information system (Product delivery records and original orders/contracts)	90 %	95 %	95 %
Innovation and improvement (i.e. the effectiveness in improving, optimizing, and innovating the current operating procedures)  Source of data: Company's internal information system (Cumulated growth rates of innovation and improvement projects, compiled based on relevant project reports)	80 %	88 %	84 %
Warehouse capability utilization (i.e. the percentage of warehouse capability used in operations)  Source of data: Company's internal information system (Warehouse inspection records)	82 %	86.1 %	90.2 %
Please rate the performance of both managers on a scale from 0-100, where 100 is the	he best performa	ince.	
Manager A			
Manager B			

Abbildung 16: Beispielhaft Darstellung der Aufgabe in Experiment 2 (Gruppe OM)

Auch in Experiment 2 wurden nach dem Experiment Kontrollfragen gestellt. Außerdem wurden wieder die Positionen der Maße variiert. Es wurden keine signifikanten Einflüsse festgestellt. Die Resultate wurden auch in Experiment 2 um Ausreißer (95 %-Ellipse und Bewertung in Summe 100) bereinigt.

Experiment 2 ermöglich einen indirekten Vergleich der Gewichtung von BBI, OM und SM. Dafür wird die Differenz der Bewertungen der Manager A und B zwischen den verschiedenen Gruppen verglichen. In der Gruppe, in der das variable Maß als BBI dargestellt wurde, lag die durchschnittliche Differenz der Bewertungen bei 1,09. Dabei wurde der Manager besser bewertet, der im variablen BBI Maß besser bewertet war. In der Gruppe OM lag die durchschnittliche Differenz bei 0,68, bei der Gruppe SM bei 0,30. Der indirekte Vergleich ergibt also, dass das algorithmische Maß in diesem Setting sogar leicht bevorzugt wurde. Dieser Unterschied der Gruppen ist allerdings nicht signifikant, die Übergewichtung von Algorithmen kann also nicht nachgewiesen werden.

Experiment 2 zeigt, dass die Resultate des ersten Experiments nicht auf einer Überlagerung von Effekten beruhen. Wird den Teilnehmern klar kommuniziert, dass die unterschiedlichen Maße sich in der Vergangenheit als gleich sensitiv und gleich valide erwiesen haben, werden sie von den Teilnehmern auch ähnlich gewichtet. Beide Ex-

perimente zeigen die generelle Akzeptanz von Menschen gegenüber Algorithmen, sofern diese sich für die betroffenen Personen in der Vergangenheit als valide und sensitiv erwiesen haben.

# 2.2.4 Fazit zu Arbeitspaket 2

Im zweiten Arbeitspaket erfolgte die Entwicklung eines Modells zur Identifikation der Faktoren, die die Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse beeinflussen. Hierauf aufbauend wurde ein Akzeptanzmodell entwickelt und im Rahmen der Online-Befragung (siehe auch AP1) validiert. Wurde ein Experiment zur Ermittlung der Akzeptanz von Algorithmen bei Entscheidungsträgern durchgeführt, in dem eine tiefgehende Analyse des Akzeptanzfaktors "Bereitgestellte Erklärung" erfolgte. Die Ergebnisse bieten eine Grundlage für die Identifikation von Biases und Akzeptanzsteigerungsmaßnahmen in den folgenden Arbeitspaketen.

# 2.3 Arbeitspaket 3

Das Arbeitspaket 3 "Identifikation von Biases, die im Kontext von durch Business Analytics gewonnenen Erkenntnissen aufkommen" dient der Identifikation von Biases, die im Kontext von durch Business Analytics gewonnenen Erkenntnissen aufkommen.

Durchgeführte Arbeiten	Erzielte Ergebnisse
Literaturreview und Experten-Workshops zur Identifikation potenzieller Bias im Kontext von Business Analytics in den Phasen des Managementprozesseses.	<ul> <li>Identifikation von kognitiven Verzerrungen (Bias), die im Kontext von durch Business Analytics gewonnen Erkenntnissen aufkommen, im Rahmen einer systematischen Literaturanalyse.</li> <li>Identifikation weiterer kognitiver Verzerrungen und Validierung aufgefundener Verzerrungen im Rahmen von Expertengesprächen und -workshops.</li> </ul>
Strukturierung der Erkenntnisse (Biases) mittels eines Literaturreview und im Rahmen von Experten-Workshops.	Ableitung einer Taxonomie 22 kognitiver Verzerrungen und 19 Handlungsempfehlungen zur Ver- meidung dieser kognitiven Verzer- rungen bei der Erstellung und In- terpretation von Erkenntnissen aus Business Analytics.
Zusammenführung zu einem Katalog validierter Biases im Kontext von Business Analytics.	<ul> <li>Zusammenführung zu einem Katalog validierter Biases im Kontext von Business Analytics.</li> <li>Ableitung von Leitfragen zur Vermeidung von Verzerrungen in der Praxis.</li> </ul>

# 2.3.1 Identifikation potenzieller Biases (Kognitive Verzerrungen) im Kontext von datengetriebenen Entscheidungen und Business Analytics

Die betriebswirtschaftliche Forschung großes Interesse an kognitiven Verzerrungen. Es gibt eine beträchtliche Menge an wissenschaftlicher Literatur, die den Einfluss kognitiver Verzerrungen auf die Entscheidungsfindung in organisatorischen Zusammenhängen diskutiert (Hutchinson et al. 2010; Schwenk 1985, 1988). Allerdings ist die Forschung hinsichtlich der Wirkung kognitiver Verzerrungen auf datengetriebene Entscheidungen knapp. In Anbetracht des stetig zunehmenden Einsatzes von BA ist ein Bedarf an der Untersuchung der Auswirkungen kognitiver Verzerrungen auf datengetriebene Entscheidungen erheblich. Vor diesem Hintergrund wurde im vorliegenden Forschungsvorhaben eine systematische Literaturrecherche durchgeführt und die ermittelten kognitiven Verzerrungen kategorisiert und mit Beispielen veranschaulicht. Einhergehend wurden die theoretischen Ergebnisse durch Interviews um Beispiele aus der Praxis ergänzt und rückgespiegelt. Im Ergebnis ergibt sich ein Katalog mit relevanten kognitiven Verzerrungen, die im Kontext von datengetriebenen Entscheidungen auftreten können. Dabei wurden nicht nur Verzerrungen, die bei der Interpretation von Entscheidungsgrundlagen bzw. Analysen hervortreten können betrachtet, sondern auch Verzerrungen, die bei der Erstellung dieser Analysen greifen.

In der wissenschaftlichen Literatur gibt es keine einheitliche Definition für den Begriff kognitive Verzerrung, auch Bias genannt. Die Ansicht, dass sich Entscheidungsträger in komplexen Umgebungen auf bestimmte Heuristiken verlassen, um die Entscheidungsfindung zu vereinfachen, ist allgemein anerkannt. Viele Forscher sind sich einig, dass diese Heuristiken nützlich sind und befriedigende Lösungen liefern können (Busenitz und Barney 1997; Ireland et al. 1987; Tversky und Kahneman 1974). Nach Das und Teng 1999 sind kognitive Verzerrungen "a negative consequence of adopting heuristics" (S. 760). Andere Forscher vertreten die Definition, dass kognitive Verzerrungen systematische Fehler sind, die durch Heuristiken entstehen (z. B. (Haley und Stumpf 1989; Ireland et al. 1987). (Haley und Stumpf 1989) stellen jedoch auch fest, dass die Konzepte der Verzerrungen und Heuristiken mehrdeutig sind und dass Wissenschaftler dazu neigen, diese Begriffe austauschbar zu verwenden. Busenitz & Barney (1997) verwenden den Begriff Verzerrungen und Heuristiken in Bezug auf Entscheidungsregeln, die Einzelpersonen zur Vereinfachung unsicherer und komplexer Situationen verwenden. In der vorliegenden Arbeit werden kognitive Verzerrungen als systematische Fehler in der Kognition definiert, die zu suboptimalen Entscheidungen oder kritischen Fehlern führen (in Anlehnung an Arnott 2006; Haley und Stumpf 1989; Ireland et al. 1987; Keil et al. 2007). Dazu können Konzepte gehören, die andere Wissenschaftler als "Heuristik" oder "Verzerrungen und Heuristik" definieren. Unabhängig von der Formulierung besteht kein Zweifel daran, dass Verzerrungen Managemententscheidungen beeinflussen können. Das und Teng 1999 stellen sogar fest, dass "kognitive Verzerrungen ein allgegenwärtiger Bestandteil der strategischen Entscheidungsfindung sind" (S. 757).

#### Literaturreview

Die systematische Literaturrecherche wurde in vier Schritten, die im Folgenden ausführlich beschrieben werden, vollführt (siehe Abbildung 17). Das Forschungsdesign ist an Webster und Watson 2002b angelehnt. Der Ansatz von Webster und Watson 2002b findet breite Anwendung (Hamari et al. 2014).

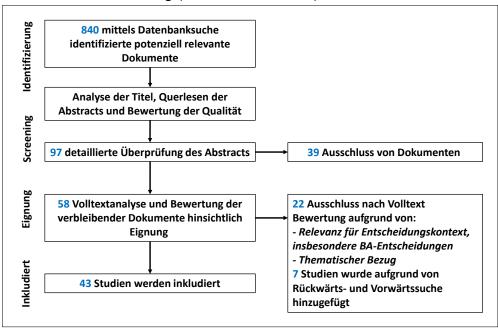


Abbildung 17: Methodik der strukturierten Literaturanalyse (eigene Abbildung)

Für die Identifizierung der relevanten wissenschaftlichen Artikel, wurde ein Suchstring eingerichtet. Dieser Suchstring sollte alle Publikationen ermitteln, die sich mit kognitiven Verzerrungen bei der Entscheidungsfindung in Organisationen befassen. Daher enthielt der Suchstring die Begriffe "bias" und "decision". Der Begriff "cognitive bias" wurde nicht verwendet, da auch einige Autoren unter einem anderen Begriff zu kognitiver Verzerrung forschen, wie z.B. "decision biases". Es wurden Publikationen über verschiedene Arten von Entscheidungsprozessen im Management (z.B. ethische oder unternehmerische Entscheidungen) in die systematische Literaturübersicht aufgenommen. Da (Tversky und Kahneman 1974) in ihren Arbeiten den Begriff "biases and heuristics" verwenden, wurde dieser Ausdruck als Umschreibung für kognitive Verzerrungen aufgenommen. Um Singular und Plural und andere Wortendungen (z.B. Entscheidungsfindung statt Entscheidung) zu berücksichtigen, wurde außerdem nach jedem Wort ein Sternchen gesetzt, da dies beliebige Wortendungen erlaubt, was letztlich zu dem folgenden, für die Suche in EBSCOhost Business Source Complete optimierten, booleanischen Suchstring führte: (cognitive bias\* OR (heuristic\* and bias\*)) AND decision\*

Die EBSCOhost Business Source Complete Datenbank enthält Volltexte von über 3.800 wirtschaftswissenschaftlichen Zeitschriften, insbesondere von Zeitschriften der angewandten Psychologie (z.B. Journal of Applied Psychology, Cognitive Science, Cognition & Emotion) und Wirtschaftspsychologie (z.B. Journal of Behavioural Decision Making, Journal of Behavioural Finance) und wurde daher als geeignet für die

Identifikation kognitiver Verzerrungen in Entscheidungssituationen betrachtet (EBSCO Publishing Inc.). Zur Gewährleistung der Qualität der identifizierten Artikel, wurde die Suche auf Artikel beschränkt, die einem Peer-Review unterzogen wurden. Die Datenbanksuche wurde zwischen dem 13. Und 15. August 2019 durchgeführt und ergab 840 Ergebnisse. Es wurden Artikel in 200 Zeitschriften identifiziert. Die meisten Artikel wurden im Journal of Behavioural Decision Making (25), Organizational Behavior & Human Decicions Processes (22), Management Science (21), Journal of Economic Psychology (16), Journal of Consumer Research (12), Psychological Science (12), Decision Sciences (11), Journal of Economic Behavior & Organization (11), Management Decision (11) und Strategic Management Journal (11) identifiziert.

#### **Durchsicht von Publikationen**

Die Ergebnisse der Suche wurden in fünf Schritten analysiert. Zunächst wurden die Titel der Artikel untersucht. Wenn der Titel darauf hinwies, dass eine Studie nicht-wirtschaftliche Themen (z.B. Recht) umfasste, wurde diese Studie nicht berücksichtigt. Wenn der Titel eindeutigen Wirtschaftsbezug hatte, dessen Inhalt jedoch nicht mit kognitiven Verzerrungen oder Entscheidungen in einem Zusammenhang gestanden hat, wurde die Arbeit ebenfalls nicht verwendet. Für die systematische Literaturübersicht wurden nur englische Arbeiten berücksichtigt.

Um eine hohe Qualität der rezensierten Literatur zu gewährleisten, wurde zweitens die Zeitschrift, in der eine Arbeit veröffentlicht wurde, nach dem BWL-Ranking des Forschungsmonitoring untersucht. Jede Quelle, die in Zeitschriften veröffentlicht wurde, die nicht in diesem Ranking aufgeführt sind oder in einer Zeitschrift mit einem schlechteren Ranking als C (Klasse 2018) veröffentlicht wurden, wurde ebenfalls aus der Studie herausgenommen. Die nach den Schritten eins und zwei übrig gebliebenen 97 Publikationen wurden für die weitere Analyse herangezogen.

Im dritten Schritt wurden die Abstracts aller gesammelten Arbeiten ausgewertet und die Publikationen kodiert. Wenn der Abstract eines Papiers darauf hingewiesen hat, dass das Thema des Papers für die Forschung über den Einfluss kognitiver Verzerrungen auf Entscheidungen im Geschäftsumfeld und insbesondere im BA-Umfeld irrelevant ist, wurde der Artikel als "nicht relevant" kodiert. Wenn der Abstract eine solche Relevanz aufgewiesen hat oder die Relevanz noch unklar gewesen ist, wurde das Papier mit "potenziell relevant" kodiert. 39 weitere Artikel wurden nach Auswertung der Abstracts ausgeschlossen.

Der vierte Schritt war die Analyse der Volltexte aller potenziell relevanten wissenschaftlichen Artikel. Dem Schritt zu Folge konnten 22 Artikel keine Relevanz aufweisen, so dass 36 Publikationen für die Literaturübersicht übriggeblieben sind.

Im fünften Schritt wurde zur Sicherstellung eine gründliche Literaturdurchsicht, zusätzlich die Referenzen der Artikel nach den bereits genannten Kriterien untersucht. Wenn

z.B. eine Arbeit zum Thema "Overconfidence" eine andere Arbeit zitierte, die sich ausschließlich mit dem Thema "Overconfidence" unter anderen Umständen befasste, wurde letztere nicht in die Literaturübersicht aufgenommen. Nach Anwendung dieses Kriteriums, der Analyse der Titel und Zusammenfassungen sowie unter Berücksichtigung der Rangliste der Zeitschriften wurden elf neue Arbeiten hinzugefügt. Vier dieser Publikationen wurden nach dem Lesen des Volltextes ausgeschlossen, so dass insgesamt 43 Arbeiten übriggeblieben sind, die Gegenstand der systematischen Literaturübersicht waren. Die Artikel, die nicht in die Literaturübersicht aufgenommen wurden, wurden meist aus einem der folgenden Gründe nicht berücksichtigt:

- Kein thematischer Bezug (Betriebswirtschaft, insbesondere BA)
- Fokus auf Entscheidungen von Konsumenten
- Kein Entscheidungskontext
- Bewertung der Zeitschrift unter C

#### Informationsextraktion

Die für die systematische Literaturübersicht relevanten Artikel wurden analysiert und Informationen über kognitive Verzerrungen extrahiert. Es wurde nach kognitiven Verzerrungen gesucht, die in Publikationen klar beschrieben wurden oder Teil einer Forschungsarbeit sind. Daher wurden kognitive Verzerrungen, die nur beiläufig (z.B. als Beispiel in der Einleitung) und ohne Bezug zur Entscheidungsfindung erwähnt wurden, weggelassen. Kognitive Verzerrungen, ihre Definitionen und ausgewählte Beispiele aus der Literatur wurden in eine Tabelle übertragen. Die systematische Durchsicht aller 43 Artikel zeigte, dass kognitive Verzerrungen in 276 Fällen erwähnt wurden. Anschließend wurden die aus der wissenschaftlichen Literatur extrahierten Definitionen unterschiedlicher Verzerrungen zu einem Katalog kognitiver Verzerrungen bei der Entscheidungsfindung zusammengefasst. Vor diesem Hintergrund wurden zudem die Bezeichnungen von kognitive Verzerrungen, da diese häufig in unterschiedlichen Bezeichnungen in der Literatur vorkommen, vereinheitlicht. Um die Validität sicherzustellen, wurden nur kognitive Verzerrungen in den Katalog aufgenommen, die in mindestens zwei verschiedenen Publikationen spezifiziert wurden.

#### **Experteninterviews und -workshops**

Das Ergebnis der systematischen Literaturübersicht ist ein Katalog von 22 kognitiven Verzerrungen, die bei der datengetriebenen Entscheidungsfindung zum Tragen kommen können. Eine detaillierte Beschreibung der kognitiven Verzerrungen und ihrer Auswirkungen, wie sie in der Literatur zu finden sind, wird im Folgenden vorgestellt (siehe Anhang für einen detaillierten Überblick darüber, welche kognitiven Verzerrungen in welchen Publikationen erwähnt werden). Der systematisch aus der Literatur erhobene Katalog wurde anschließend mit einer Analyse von Beschreibungen von Entscheidungssituationen gespiegelt und hinsichtlich möglicher Ergänzungen geprüft. Diese Situationsbeschreibungen wurden im Rahmen von Experteninterviews und workshops erhoben. Auf Situationsbeschreibungen wurde zurückgegriffen, da eine ex-

plorative Befragung nach dem Aufkommen von kognitiven Verzerrungen nur eingeschränkte Erkenntnisse hervorbrachte. Situationsbeschreibungen wurden beispielsweise zu Fragestellungen wie "Welche Hürden haben sich in Ihrem Unternehmen bei der Visualisierung und beim Reporting von Daten ergeben?", "Aus welchen Gründen wird BA in Ihrem Unternehmen im Bereich Infrastruktur gar nicht oder nur wenig angewandt?" oder "Haben Sie schon mal Situationen erlebt, wo Sie Erkenntnisse aus BA bewusst ignoriert haben bzw. nicht darauf vertraut haben? Wenn ja, wieso?" ermittelt. Im spezifischen wurden zur Identifikation von kognitiven Verzerrungen, Situationsbeschreibungen aus zwei Workshops (Q3 2019, Q1 2020), Freitextantworten einer Online-Umfrage unter 51 Experten (siehe AP1) und 31 semi-strukturierten qualitativen Interviews (Q3 2020) analysiert. Im Rahmen der Analyse der Situationsbeschreibungen konnten keine weiteren kognitiven Verzerrungen identifiziert werden, die nicht bereits im bestehenden Katalog vorhanden waren. Jedoch fanden sich in den Beschreibungen kognitive Verzerrungen aus dem bestehenden Katalog mehrfach wieder. Beispielsweise ließen Aussagen, wie "Erfahrung wird höher gewichtet" auf den Overconfidence Bias schließen. Zudem deutete dies auf eine ausreichende Sättigung des Bias-Katalog hin. Darüber hinaus konnten aus den Beschreibungen Praxisbeispiele zur Veranschaulichung der kognitiven Verzerrungen entnommen werden. Diese wurden zudem um Beispiele aus der Literatur ergänzt. Eine Auswahl der kognitiven Verzerrungen und Beispiele wurde zudem in zwei Online-Workshops (Q4 2019) mit Praxispartnern validiert.

#### 2.3.2 Strukturierung der Erkenntnisse (Biases)

Die 22 kategorisierten kognitiven Verzerrungen wurden anhand einer mehrdimensionalen Matrix (Dimensionen: soziale, technische und Umweltaspekte) strukturiert, welche die Identifikation von potenziellen Verzerrungen anhand interner und externer Einflüsse zulässt (siehe Tabelle 1). Die kognitiven Verzerrungen wurden dabei zur effizienteren Kategorisierung jeweils nur einer Dimension zugeordnet, obwohl Überschneidungen zwischen den Dimensionen denkbar sind.

Soziale Aspekte umfassen interne Einflüsse, wie das Selbstvertrauen des Entscheidungsträgers, die das Aufkommen der kognitiven Verzerrung begünstigen. Soziale Aspekte sind vor diesem Hintergrund eindeutig an den jeweiligen Entscheidungsträger gebunden, was auf eingeschränkte Möglichkeiten für die Vermeidung der Verzerrungen schließen lässt. Denn eine Vermeidung der kognitiven Verzerrung würde beispielsweise ein Einwirken auf die Selbstwahrnehmung des Entscheidungsträgers bedingen.

Technische Aspekte umfassen Eigenschaften der zu betrachteten Entscheidungsgrundlage, die das für das Aufkommen der kognitiven Verzerrungen begünstigen. So beschäftigt sich diese Dimension beispielsweise mit der Größe der Stichprobe, die bei einer datengetriebenen Entscheidungsfindung zum Einsatz kommt. Die der techni-

schen Dimension zugeordneten kognitive Verzerrungen, können potenziell von Erklärungen oder Warnungen, die der Entscheidungsgrundlage angehängt werden, bestimmt werden. Möglichkeiten zur Gestaltung der Entscheidungsgrundlage, insbesondere in Hinblick auf die dabei entstehende Akzeptanzwirkung, wurden in Arbeitspaket 4 weiter beleuchtet.

Umweltaspekte umfassen externe (auch unternehmensexterne) Einflüsse und Situationen, die im Moment der Entscheidungsfindung auf den Entscheidungsträger einwirken oder in der Vergangenheit auf den Entscheidungsträger eingewirkt haben. So bestimmt sich beispielsweise das Vorhandensein der Verfügbarkeitsverzerrung dadurch, ob ein Manager bereits in der Vergangenheit ein vergleichbares Ereignis erlebt hat. Ähnlich der sozialen Aspekte, lassen Umweltaspekte auf nur eingeschränkte Möglichkeiten für die Vermeidung der Verzerrungen schließen, da sich diese nicht unmittelbar durch Erweiterung oder Anpassung der Entscheidungsgrundlage realisieren lassen, sondern zumeist auf den Erfahrungen des jeweiligen Entscheidungsträgers beruhen.

Vor dem Hintergrund der Strukturierung der kognitiven Verzerrungen bei der strategischen Entscheidungsfindung nach sozialen, technischen und Umweltaspekten, zeigt sich, dass technische Aspekte das Aufkommen von 40% der mit dem Katalog identifizierten Bias begünstigen. Weiterhin begünstigen soziale Aspekte weitere 40% der mit dem Katalog identifizierten Bias. Daher lässt die Strukturierung schließen, dass beispielsweise die systematische Gestaltung datengetriebener Ergebnisse und Trainings von Entscheidungsträgern Möglichkeiten für die Handhabbarkeit kognitiver Verzerrungen im Business Analytics Entscheidungsprozess darstellen. Diese Art von Vermeidungsmethoden werden in AP4 weiter erörtert.

Tabelle 6: Kategorisierung der ermittelten Verzerrungen

Dimension	Einflüsse	Kognitive Verzerrungen
Soziale Aspekte	Interne Einflüsse begünsti-	Illusion of Control, Overconfidence,
	gen kognitiven Verzerrung	Overoptimism, Preferred alterna-
		tives, Reasoning by analogy, Recol-
		lection, Selective perception, Self-at-
		tribution, Status quo
Technische As-	Eigenschaften der zu be-	Devaluation of partially described al-
pekte	trachteten Entscheidungs-	ternatives, Law of small numbers,
	grundlage begünstigen	Misconceptions of chance, Redun-
	kognitiven Verzerrung	dancy, Representativeness, Satisfic-
		ing, Statistical misconceptions, Vivid-
		ness
Umweltaspekte	Externe (auch unterneh-	Adjustment and anchoring, Availabil-
	mensexterne) Einflüsse	ity, Escalating commitment, Hind-
	und Situationen begünsti-	sight
	gen kognitive Verzerrung	

#### **Soziale Aspekte**

Illusion of Control (deutsch: Illusion von Kontrolle). Entscheidungsträger neigen dazu die eigenen Fähigkeiten im Hinblick auf die Bewältigung künftiger Ereignisse zu überschätzen (Simon et al. 2000). Personen, die sich der Kontrollillusion hingeben, schätzen ihre Fähigkeit, die Ergebnisse einer Strategie durch persönliche Anstrengung zu kontrollieren, unrealistisch ein (Schwenk 1985). Sie glauben fälschlicherweise, dass sie jegliche potenzielle zukünftige Probleme lösen können (Das und Teng 1999).

#### Beispiele aus der Business Analytics Praxis

Ein Entscheidungsträger der Maier GmbH missachtet im Rahmen der Durchsicht von Reports, die vom hauseigenen Analyseteam erstellt wurden, unwahrscheinliche, negative Absatzprognosen, die auf den ersten Blick durch geeignete strategische Maßnahmen kontrollierbar erscheinen. Nötige Gegenmaßnahmen für den Eintritt der unwahrscheinlichen Absatzprognosen, wie die Beauftragung zum Aufbau eines Online-Shops für den Ausgleich temporär geschlossener Verkaufsgeschäfte, werden aufgrund dieser falschen Einschätzung vom Entscheidungsträger der Maier GmbH nicht eingeleitet.

Overconfidence (deutsch: Übersteigertes Selbstvertrauen). Entscheidungsträger neigen dazu ihr Wissen und die Genauigkeit ihrer Annahmen zu überschätzen (Forbes 2005). Sie empfinden ein objektiv unbegründetes Vertrauen in ihre Einschätzung von Situationen und verhalten sich so, als ob die vorhergesagten Ergebnisse von zweideutigen Ereignissen sicher wären (Busenitz und Barney 1997; Li 2019). Das kann dazu führen, dass sie das potenzielle Risiko unsicherer Situationen außer Acht lassen (Simon et al. 2000). Dies zeigt sich beispielsweise wenn Personen gebeten werden, zu schätzen, wie viele Bücher im Jahr 2013 im Springer Gabler-Verlag neu erschienen sind. Als Antwort soll keine genaue Schätzung abgegeben werden, sondern ein vonbis-Intervall, das den wahren Wert mit einer bestimmten, vorgegebenen Wahrscheinlichkeit enthalten soll. Overconfidence manifestiert sich darin, dass das Intervall regelmäßig zu eng angegeben wird und so der wahre Wert häufig verfehlt wird. Dies wird auch als Miscalibration bezeichnet (Gillenkirch 2018).

#### Beispiele aus der Business Analytics Praxis

Das Analyseteam der Maier GmbH überschätzt die eigenen Fähigkeiten in der Ableitung von Annahmen für die Erstellung von Umsatzprognosen für ein neues Marktsegment. Daher, werden bei der Erstellung der Umsatzprognosen nur finite Annahmen für einzutretende Ereignisse und damit für die Prognoseerstellung eingesetzt. Eine umfassende Szenarioanalyse, die eine Variabilität einzelner Annahmen, z.B. über das Marktwachstum, und deren Kombination vorhersieht, und damit die Entscheidungsqualität verbessern könnte, wird nicht durchgeführt.

Overoptimism (deutsch: Übertriebener Optimismus). Entscheidungsträger lassen sich von den eigenen Präferenzen für einen Ausgang bei ihrer Bewertung über die Wahrscheinlichkeit des Ausgangs beeinflussen (Hogarth und Makridakis 1981). Dabei schätzen Führungskräfte die Wahrscheinlichkeit eines erwünschten Ergebnisses häufig höher ein, als sie objektiv tatsächlich ist (Schwenk 1988). Dies führt beispielsweise

dazu, dass scheiternde Projekte häufig fortgeführt werden, da Entscheidungsträger glauben, Überschreitungen prognostizierter Kosten oder Zeitüberschreitungen zu Beginn eines Projekts mittels eigener Managementfähigkeiten später aufholen zu können. Zudem begründen Entscheidungsträger die Fortführung von Projekten, mit dem Glauben, dass das Projekt erst nach Abschluss größere Business Vorteile mit sich bringen wird (Meyer 2014).

# Beispiele aus der Business Analytics Praxis

Ein Entscheidungsträger der Maier GmbH geht bei der Durchsprache von Absatzentwicklungsszenarien grundsätzlich vom Best Case aus. Entsprechend wird die zukünftige Strategie, z.B. im Hinblick auf Bestellmengen, nach dem Best Case Szenario ausgerichtet. Die Erwartungshaltung an das Tagesgeschäft richtet sich entsprechend auch nach dem bestmöglichen Ergebnis.

Preferred alternatives (deutsch: Bevorzugte Alternativen). Entscheidungsträger konzentrieren sich möglicherweise nur auf einen Wert oder ein Ziel anstatt alle entscheidungsrelevanten Ziele in Betracht zu ziehen und leiten eine einzige Entscheidungsalternative ab, um dieses Ziel zu erreichen (Schwenk 1984). Sie neigen dazu, positive Ergebnisse für die bevorzugte Alternative und negative Ergebnisse für die nicht bevorzugten Alternativen abzuleiten. Entscheidungsträger können sich selbst davon überzeugen, dass die Umsetzung nicht bevorzugter Alternativen unmöglich ist, indem sie zusätzliche Anstrengungen zur Bestimmung negativer Aspekte unternehmen. Darüber hinaus können Entscheidungsträger Beweise so interpretieren, dass die bevorzugte Alternative auf vielfältiger Art zu dienen scheint und kaum Kosten verursacht (Schwenk 1985). Dieses Verhalten kann dazu führen, dass durchführbare Alternativen abgelehnt und die Generierung von Alternativen vorzeitig gestoppt wird (Schwenk 1984). Ein Beispiel ist, wenn bei Betrachtung einer schlecht laufenden Geschäftseinheit neben einer Desinvestition und möglichen Abstoßung keine einzigen weiteren Entscheidungsalternativen berücksichtigt werden (Duhaime und Schwenk 1985).

# Beispiele aus der Business Analytics Praxis

Ein Entscheidungsträger der Maier GmbH selektiert aus einem Wettbewerbsreport einzelne Analysen und interpretiert diese zugunsten der gleichen Entscheidungsalternative. Erweiterungen und Anpassungen des Reports werden nur hinsichtlich der ausgewählten Entscheidungsalternative in Auftrag gegeben.

Reasoning by analogy (deutsch: Argumentation durch Analogie). Vereinfachungen und Analogiebildungen können dazu führen, dass Entscheidungsträger wichtige Informationen übersehen und Situationen vertrauter wahrnehmen, als sie tatsächlich sind (Haley und Stumpf 1989; Simon und Houghton 2002). Dies tritt beispielsweise auf, wenn Führungskräfte einfache Analogien und Bilder auf komplexe Situationen anwenden, um Problemdefinitionen zu gestalten. Diese Analogien tragen dazu bei, die wahrgenommene Unsicherheit zu verringern und in Führungsteams ein gemeinsames Problemverständnis zu entwerfen (Duhaime und Schwenk 1985; Schwenk 1985). Ein Beispiel findet sich im Rahmen der Lieferkettenoptimierung hat ein Fahrzeugbauer die

Strategie der virtuellen Integration der Zulieferer eines PC-Herstellers als potenzielle Analogie betrachtet. Oberflächlich ähneln sich Computer- und Autoproduktion. Beide beinhalten den Zusammenbau einer großen Vielfalt von Modellen aus einer Reihe von ziemlich standardisierten Komponenten. Es ist jedoch leicht, Unterschiede zwischen den beiden Industrien zu erkennen. Im PC-Geschäft zum Beispiel sinken die Preise der Bauteile um bis zu 1% pro Woche - viel schneller als in der Automobilindustrie. Da die sinkenden Kosten für den Erfolg der Strategie von PC-Herstellers relevant sein könnten, hätte die Nichtberücksichtigung des Sachverhalts zu einer fehlerhaften Analogie führen können (Giovanni Gavetti & Jan W. Rivkin 2005).

#### Beispiele aus der Business Analytics Praxis

Bei der Durchsprache einer neueingeführten nach Kunden segmentieren Analyse im monatlichen Jour Fixe der Marketingabteilung der Maier GmbH wird die neue Analyse mit einer stark vereinfachten Analogie vorgestellt. Die zugrundeliegende Methodik zur Erstellung der Analyse und damit zur Segmentierung der einzelnen Kundengruppen geht dabei unter. Bei zukünftigen Jour Fixe, wird weiterhin die Analogie herangezogen. Probleme in der Analysemethodik fallen nicht oder erst spät auf.

Recollection (deutsch: Erinnerung). Die Fähigkeit von Entscheidungsträgern, aus der Vergangenheit zu lernen, kann durch Verzerrungen bei der Erinnerung eingeschränkt sein. Vergangene Strategien können als rationaler in Erinnerung gerufen werden, als sie es waren (Schwenk, 1995). Schwierigkeiten beim Erinnern von Details vergangener Ereignisse können zu einer ungenauen Rekonstruktion führen, die vom Entscheidungsträger immer noch als logisch empfunden wird (Hogarth und Makridakis 1981; Loftus 1975; Schwenk 1988). Ein Beispiel für Recollection ist, dass über 60% der Befragten in einer nationalen US-Stichprobe von über 900 Erwachsenen glauben, dass das gegenwärtige Risiko eines zukünftigen Terroranschlags entweder durch ein Flugzeug oder in einer öffentlichen Umgebung geringer ist, als sie es vor dem 9/11-Anschlag bzw. vor dem Bombenanschlag beim Boston-Marathon geglaubt haben. Unter rationalen Gesichtspunkten müssten die Probanden eigentlich nach diesen Ereignissen ein höher eingeschätztes Risiko angeben (Viscusi und Zeckhauser 2017).

# Beispiele aus der Business Analytics Praxis

Entscheidungsträger der Maier GmbH verlassen sich nur auf aktuelle Reports und Analysen und ignorieren historische Daten, die die Maier GmbH bereits seit vielen Jahren archiviert, da sie davon ausgehen diese noch gut erinnern zu können.

Selective perception (deutsch: Selektive Wahrnehmung). Die Erwartungen eines Entscheidungsträgers bezüglich einer Situation verzerren sowohl die für relevant befundenen Informationen als auch mögliche Beobachtungen (Arnott 2006; Schwenk 1984, 1988). Entscheidungsträger suchen nach Beweisen, die ihre Erwartungen bestätigen, während sie Informationen, die mit ihren Überzeugungen unvereinbar sind, herunterspielen oder vernachlässigen (Hogarth und Makridakis 1981; Kirs et al. 2001). Dieses Phänomen tritt bspw. bei Produktneueinführugen auf. Der CEO hat beispielsweise "die

Idee der Zukunft" gefunden und weist sein Team an Marktforschung zu betreiben. Statt Daten sprechen lassen zu lassen, kommt es zur einer Bestätigungsverzerrung: Die Marktforschung wird als Basis genutzt um die eigenen Meinungen zu bestätigen. Beim Produktentwicklungsprozess sind die Fragen zudem so verzerrt, damit die Antworten resultieren, die dem CEO gefallen (Hammond 2016).

# Beispiele aus der Business Analytics Praxis

Ein Entscheidungsträger der Maier GmbH setzt das Analyseteam unter Druck, Daten zu sammeln die ihm/ihr bei der Zielsetzung im Unternehmen unterstützen. Das Analyseteam gibt schließlich nach und liefert ausschließlich Analysen die auf den Daten basieren, die den Anforderungen des Entscheidungsträgers entsprechen, obwohl weitere Daten vorliegen die diesen auch entgegensprechen.

Self-attribution (deutsch: Einschätzungsvermögen). Da Entscheidungsträger in der Regel Ergebnisse nicht vollständig beobachten können, können sie einige Aspekte und Konsequenzen einer Entscheidung nicht testen. Gewöhnlich bleiben die Folgen von Entscheidungsalternativen, die nicht gewählt wurden, unbekannt. Dies kann zu übermäßigem Vertrauen in das eigene Urteilsvermögen führen (Arnott, 2006; Hogarth & Makridakis, 1981). Entscheidungsträger neigen auch dazu, den Erfolg ihren eigenen Fähigkeiten zuzuschreiben, während sie das Scheitern auf Pech zurückführen (Chen et al. 2015). So konnte beispielsweise gezeigt werden, dass Investoren sich den Erfolg eines Investments bei hohen Renditen eher ihren Investmentfähigkeiten zuschreiben, als bei niedrigen Renditen (Hoffmann und Post 2014).

#### Beispiele aus der Business Analytics Praxis

Beim Eintreten des Worst Case Szenarios, welchen vom Analyseteam der Maier GmbH ermittelt wurde, hinterfragt ein Entscheidungsträger nicht, ob die eigenen Entscheidungen und Fähigkeiten für das Eintreten des Szenarios verantwortlich sind.

Status quo. Entscheidungsträger reagieren auf externe Störfaktoren tendenziell wenig agil (Sibony et al. 2017). Sie können in gewisser Weise oder auch gar nicht operieren, um den Status quo zu erhalten (Zeni et al. 2016). Dies lässt sich durch die Neigung von Einzelpersonen erklären, risikoavers zu sein. Sie behalten also eher den Status quo bei, als Verluste zu riskieren (Kahneman et al. 1991). Entscheidungsträger sind auch oft geneigt, frühere Entscheidungen zu wiederholen (Burmeister und Schade 2007). Der Status Quo Bias zeigt sich meistens dort wo das Tätigsein eher oder stärker bestraft werden als das Untätigsein. So scheitern beispielsweise viele Unternehmensfusionen daran, dass übernehmende Unternehmen den zu übernehmenden Unternehmen nicht direkt eine neue ordentliche Managementstruktur aufzwingen wollen. Dies führt dazu, dass sich mit der Zeit die bestehende Struktur verfestigt und es schwerer wird diese im Nachhinein zu ändern (John S. Hammond, Ralph L. Keeney, and Howard Raiffa 1998).

#### Beispiele aus der Business Analytics Praxis

Mittels eines BA-Systems werden Umsätze in Echtzeit erfasst. Die historischen Daten deuten auf eine kontinuierliche positive Umsatzenwicklung hin. Der Erfolg in der Vergangenheit lässt Entscheidungsträger keine Abweichungen von der Strategie der letzten Quartale vollziehen. Das Analyseteam erstellt Vorhersagen aus den historischen Daten und erläutert, dass dem Unternehmen auf längere Sicht Verluste entstehen können, wenn kein kurzfristiger Strategiewechsel erfolgt.

#### **Technische Aspekte**

Devaluation of partially described alternatives (deutsch: Abwertung von nicht vollständig beschriebenen Alternativen). Entscheidungsträger lassen sich durch den Detailgrad der Beschreibung von Entscheidungsalternativen in ihrer Entscheidungsfindung beeinflussen. Entscheidungsalternativen werden häufig nicht gleich detailliert beschrieben. Da weniger ausführlich beschriebene Alternativen mit Unsicherheit verbunden sind, bewerten Entscheidungsträger diese Alternativen eher negativ (Schwenk 1984).

#### Beispiele aus der Business Analytics Praxis

Die Unsicherheitsaversion die durch unvollständige Informationen in einem BA-System zur Investitionsentscheidung für eine neue Produktionsanlage hervorgerufen wird, kann dazu führen, dass ein Entscheider bestimmte Investitionen in bestimmten Märkten nichttätigen, wenn für alternativen Handlungsoptionen vollständigere Informationen vorliegen

Framing. Entscheidungsträger lassen sich durch die Art und Weise, wie ein Problem oder eine Information präsentiert wird, ihr ihrer Entscheidungsfindung beeinflussen (Mowen und Mowen 1986). Der vielleicht populärste Effekt des Framing ist die unterschiedliche Wahrnehmung von Gewinnen und Verlusten. Der wahrgenommene Nutzen potenzieller Gewinne ist in der Regel geringer als der wahrgenommene Nutzen potenzieller Verluste desselben Geldwerts (Cripps und Meyer 1994). So führen Erwartungsnutzen-gleiche Entscheidungsalternativen die wie Gewinne formuliert werden, zu risikoscheuen Entscheidungen, während Entscheidungsalternativen, die wie Verluste formuliert werden, zu risikosuchenden Entscheidungen führen (Miller und zur Shapira 2004). Ein weiteres Beispiel für die Verzerrung durch Framing ist die Anordnung von Informationen: In einer Liste werden beispielsweise der erste und der letzte Punkt häufig als besonders wichtig angesehen (Arnott 2006; Chpman et al. 1996). Ein weiteres klassisches Beispiel ist eine Aufgabe von Tversky und Kahnemann (1981). (Tversky und Kahneman 1981) baten ihren Studenten sich vorzustellen, dass sich die USA auf eine asiatische Krankheit vorbereiten, an der voraussichtlich 600 Menschen sterben werden. Es gibt zwei Programme, die den Studenten vorgestellt werden, um mit dem Problem umzugehen.

	Program A	Program B
Ergebnis-	200 Menschen	Eine Wahrscheinlichkeit von 1/3, dass
darstellung	werden geret-	600 Personen gerettet werden, und eine
1 (ED1)	tet	Wahrscheinlichkeit von 2/3, dass keine
		Person gerettet wird
Ergebnis-	400 Menschen	Wahrscheinlichkeit von 1/3, dass nie-
darstellung	werden ster-	mand sterben wird, und eine Wahrschein-
2 (ED2)	ben	lichkeit von 2/3, dass 600 Personen ster-
		ben werden

Obwohl beide Programme die gleiche Anzahl von Todesfällen zur Folge haben, aber auf unterschiedliche Weise gestaltet sind, ergaben sich folgende Ergebnisse:

ED1: 72 Prozent wählten das Programm A (Positives Framing)

ED2: 22% wählten das Programm B (Negatives Framing)

# Beispiele aus der Business Analytics Praxis

Die Visualisierung der Overall Equipment Effectivness (OEE) einer Produktionslinie wird derart eingeschränkt dargestellt, dass ein positiverer Eindruck entsteht, als wenn OEE für einen längeren Zeitraum angezeigt werden würde.

Law of small numbers (deutsch: Gesetz der geringen Anzahl). Entscheidungsträger neigen dazu, die Bedeutung kleiner Stichproben zu überschätzen (Schwenk 1988). (Simon und Houghton 2002) halten fest, "kleine Stichproben sind variabel und haben keine prädiktive Validität" (S. 113). Dennoch ziehen Entscheidungsträger nach wie vor Schlussfolgerungen aus kleinen Stichproben, vernachlässigen deren geringen Vorhersagewert und treffen daher verzerrte Urteile (Houghton et al. 2000). Beispielsweise stellten (Tversky und Kahneman 1974) Teilnehmern einer Studie die folgende Aufgabe:

Eine Stadt wird von zwei Krankenhäusern versorgt. In dem größeren Krankenhaus werden jeden Tag etwa 45 Babys geboren. In dem kleineren Krankenhaus werden jeden Tag etwa 15 Babys geboren. Wie Sie wissen, sind etwa 50 Prozent aller Babys Jungen. Der genaue Prozentsatz der geborenen Jungen variiert jedoch von Tag zu Tag. Manchmal kann er höher als 50 Prozent sein, manchmal niedriger. Ein Jahr lang erfasste jedes Krankenhaus die Tage, an denen mehr als 60 Prozent der Babys als Jungen geboren wurden. Welches Krankenhaus hat Ihrer Meinung nach mehr solcher Tage registriert?

- a. Das größere Krankenhaus
- b. Das kleinere Krankenhaus
- c. Ungefähr dasselbe (d.h. innerhalb von 5 Prozent voneinander)

Die meisten Menschen entscheiden sich für C und erwarten, dass die beiden Krankenhäuser eine ähnliche Anzahl von Tagen verzeichnen, an denen 60 Prozent oder mehr der geborenen Babys Jungen sind. Die Leute scheinen eine grundlegende Vorstellung davon zu haben, wie ungewöhnlich es ist, dass 60 Prozent eines zufälligen Ereignisses auftreten. Die Statistik sagt uns jedoch, dass wir in einer kleineren Stichprobe mit sehr viel höherer Wahrscheinlichkeit 60 Prozent der männlichen Babys beobachten als in einer größeren Stichprobe.

## Beispiele aus der Business Analytics Praxis

Eine zu kleine Stichprobe als Basis für Analysen der Bedarfsentwicklung eines bestimmten Kundensegments mittels eines BA-Systems führt dazu, dass die Ergebnisse der Analyse zu falschen Schlüssen führen können. Diese Stichproben spiegeln nicht die Grundgesamtheit der Population wider. Eine mögliche Folge ist die ungünstige Allokation des Marketingbudgets.

Misconceptions of chance (deutsch: Fehleinschätzung des Zufalls). Entscheidungsträger neigen dazu, Wahrscheinlichkeiten falsch einzuschätzen. Daraus ergibt sich die Tendenz, die Bedeutung einer Reihe ähnlicher Ereignisse in einem Zufallsprozess zu überschätzen. Entscheidungsträger können entweder davon ausgehen, dass ein weiteres ähnliches Ereignis eintreten wird, oder dass die Wahrscheinlichkeit eines nicht kürzlich beobachteten Ereignisses zunimmt (Hogarth und Makridakis 1981; Kirs et al. 2001). Entscheidungsträger können auch eine Reihe zufälliger Ereignisse mit einem grundlegenden Merkmal des zugrunde liegenden Prozesses verwechseln (Arnott 2006; Ayton et al. 1989). Als Beispiel stellten (Tversky und Kahneman 1981) folgende Frage an die Teilnehmer einer Studie:

Wenn eine faire Münze viermal geworfen wird, welche der folgenden geordneten Abfolge von Kopf (K) und Zahl (Z), wenn überhaupt, ist am wahrscheinlichsten?

(a) K Z K Z; (b) K K Z K; (c) Z K K Z; (d) K K K; (e) Alle Sequenzen sind gleich wahrscheinlich

Alle Ergebnisse sind gleich wahrscheinlich, aber die meisten Menschen entscheiden sich für (a), da es "eher zufällig aussieht". Viele vergleichen Ergebnisse mit ihrem Idealbild, dass Würfe zufällig aussehen, und halten Ergebnisausprägungen die dem Idealbild entsprechen am wahrscheinlichsten.

#### Beispiele aus der Business Analytics Praxis

Ein Business Analytics System zur Ermittlung der Marktentwicklung kann als untauglich eingestuft werden und der Einsatz dieses Systems eingestellt werden, obwohl es in den meisten Fällen durch die Vorhersage einen deutlichen Mehrwert geschaffen hätte.

Dieses Szenario kann bspw. eintreten, wenn die Vorhersagen in einem normalen Marktumfeld sehr zutreffend gewesen wären, aber aufgrund nicht zu erwartender zufälliger Ereignisse, sehr weit daneben liegen. Wenn es sich bei diesem unerwartetem Ereignis bspw. um die Corona Pandemie handelt, ist die Abweichung des BA Systems offensichtlich und der Mehrwert wird nicht so stark in Fragegestellt, wie wenn es etwas subtileres ist, wie bspw. eine Veränderung der Abschreibungsregelung und der damit verbundenen Erhöhung der Investitionen in einem bestimmten Zielmarkt.

Redundancy (deutsch: Redundanz). Entscheidungsträger neigen dazu, Entscheidungsalternativen mit redundanten Informationen falsch einzuschätzen. Obwohl Datenredundanz keine größere Vorhersagegenauigkeit impliziert, haben Entscheidungsträger mehr Vertrauen in die Genauigkeit und Bedeutung redundanter, voluminöser Daten (Hogarth und Makridakis 1981). Dabei ist beispielsweise die innere Konsistenz eines Musters von Eingaben eine wichtige Determinante für das Vertrauen in Vorhersagen, die auf diesen Eingaben basieren. So äußern Menschen mehr Vertrauen in die Vorhersage des Notendurchschnitts eines Studenten, der im ersten Jahr nur die Note 2 erhalten hat, als in die Vorhersage des Notendurchschnitts eines Studenten, dessen Durchschnitt im ersten Jahr oftmals die Noten 1 und 3 enthalten. Äußerst konsistente Muster werden am häufigsten beobachtet, wenn die Eingabevariablen hochgradig redundant oder korreliert sind. Daher neigen Menschen dazu, großes Vertrauen in Vorhersagen zu haben, die auf redundanten Eingabevariablen basieren. Allerdings erreichen Eingabevariablen oftmals eine höhere Genauigkeit, wenn sie unabhängig voneinander sind. Daher verringert die Redundanz zwischen den Eingaben die Genauigkeit, selbst wenn sie das Vertrauen erhöht, und die Menschen sind oft zuversichtlich bei Vorhersagen, die mit großer Wahrscheinlichkeit falsch sind (Kahneman 2012).

#### Beispiele aus der Business Analytics Praxis

In einem Dashboard eines Business Analytics Systems zur Ermittlung und Darstellung der relevanten Kennzahlen zur Beurteilung der Produktionsqualität werden alle Kennzahlen als Graph oder Wert angezeigt. Nur die Kennzahl First Pass Yield (FPY) wird als Graph in einem Diagramm und die Entwicklung des gleichen Betrachtungszeitraums in einer Tabelle angegeben. Dies kann zu einer Übergewichtung des FPY führen und Entwicklungen bei anderen Werten in den Hintergrund rücken.

Representativeness (deutsch: Repräsentativität). Entscheidungsträger können das Ausmaß überschätzen, in dem eine Situation oder eine Stichprobe repräsentativ für die Situation oder Population ist, auf die verallgemeinert werden soll (Schwenk 1985). Dies führt zu übermäßig vereinfachten Vorhersagen und unangemessenen Schlussfolgerungen aus einer kleinen Anzahl von Beobachtungen (Kirs et al. 2001; Schwenk 1984). Da die Entscheidungsträger Annahmen zu einer begrenzten Anzahl von Kriterien treffen, vernachlässigen sie Informationen über die zu Grunde liegenden Wahrscheinlichkeiten (Barnes 1984; Tversky und Kahneman 1974). (Kahneman und Tversky 1972) illustrierten das Phänomen der Repräsentativität in einer Studie. Die Teilnehmer erhielten eine kurze Beschreibung einer Person, die Spaß am Rätseln hatte und sowohl mathematisch veranlagt als auch introvertiert war. Einigen Teilnehmern wurde gesagt, dass diese Beschreibung aus einer Gruppe von 70 Ingenieuren und 30 Juristen ausgewählt wurde. Anderen wurde gesagt, dass die Beschreibung aus einer Liste von 30 Ingenieuren und 70 Anwälten stammte. Als nächstes wurden die Teilnehmer gebeten, die Wahrscheinlichkeit einzuschätzen, dass es sich bei der beschriebenen Person um einen Ingenieur handelt. Obwohl den Teilnehmern bewusst war, dass die Kurzbeschreibung kein sicheres Mittel zur Unterscheidung zwischen Juristen und Ingenieuren bietet, neigten die meisten dazu, dass die Beschreibung von einem Ingenieur stammt. Ihre Einschätzungen waren relativ unabhängig gegenüber Unterschieden in der Grundgesamtheit der Ingenieure (70% gegenüber 30% der Stichprobengruppe). Die Teilnehmer verwenden zu Grunde liegen Wahrscheinlichkeiten korrekt, wenn keine anderen Informationen angegeben werden.

# Beispiele aus der Business Analytics Praxis

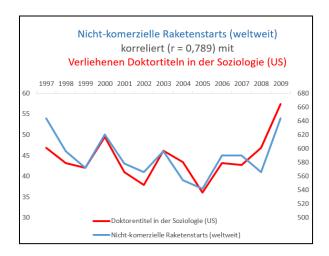
Eine Business Analytics Anwendung zur Unterstützung des technischen Einkaufs bei der Kalkulation von Spritzgussbauteilen, wurde im Rahmen einer Kooperation mit einem Lehrstuhl entwickelt. Obwohl die Leistung des Tools mindestens vergleichbar mit der von den kalkulierenden Mitarbeitern, wurde das Tool wegen der rudimentären Visualisierung vom Management abgelehnt.

Satisficing (deutsch: Zufriedenstellung). Entscheidungsträger neigen dazu, Informationssuchen vorzeitig abzubrechen. Wenn sie mit einer großen Datenmenge konfrontiert werden, kann dann nur eine kleine Teilmenge dieser Daten extrahiert werden (Kirs et al. 2001). Auch eine scheinbar vollständige Datenpräsentation kann dazu führen, dass die Suche nach weiteren Informationen gestoppt wird, und dass weitere zielführende Daten vernachlässigt werden (Arnott 2006; Fischhoff et al. 1978). Vor diesem Hintergrund neigen beispielsweise Verbraucher dazu nicht den maximalen Nutzen, sondern nur ein befriedigendes Nutzenniveau anzustreben. Bei der Suche bspw. nach einem Handyvertrag kann ein Verbraucher dazu geneigt sein, nicht den maximalen Nutzen, d. h. den Vertrag mit dem individuell bestes Preis-Leistungs-Verhältnis anzustreben, sondern die Suche nach der Sichtung eines Teils der verfügbaren Angebote abzubrechen und somit nur ein befriedigendes Nutzenniveau anzustreben.

#### Beispiele aus der Business Analytics Praxis

Ein Business Analytics System, dessen Ausgabe in einem Dashboard mit vielen Ansichten resultiert, birgt die Gefahr in sich, dass der Anwender bereits nach wenigen Ansichten die Informationsaufnahme abbricht. Die Entscheidung, die anschließend basierend auf den Daten getroffen wird, kann damit auf falschen oder unvollständigen Annahmen beruhen.

Statistical misconceptions (deutsch: Statistischen Fehleinschätzungen). Entscheidungsträger können mehreren statistischen Fehleinschätzungen zum Opfer fallen. Einzelpersonen neigen dazu, die Wahrscheinlichkeit zusammengesetzter konjunktiver Ereignisse zu überschätzen und die Wahrscheinlichkeit zusammengesetzter disjunktiver Ereignisse zu unterschätzen (Arnott 2006; Tversky und Kahneman 1973). Bei der Beurteilung von Häufigkeiten verlassen sich die Entscheidungsträger fälschlicherweise auf absolute statt auf relative Zahlen (Hogarth und Makridakis 1981). Auch die Nichtberücksichtigung von Regressionseffekten ist ein Teil dieser Verzerrung (Schwenk 1988). Mathematische Modelle können Entscheidungsträger dazu verleiten, Korrelation mit Kausalität zu verwechseln (Barnes 1984). Als Beispiel korrelieren die weltweiten nicht-kommerziellen Raketenstarts mit der Anzahl der verliehenen Doktortitel in den USA (r = 0,789). In diesem Fall lässt sich eine Kauslität relativ einfach ausschließen, jedoch ist dies nicht bei jeder Korrelation, der keine Kausalität zu Grunde liegt derart offensichtlich (Vigen 2020).



# Beispiele aus der Business Analytics Praxis

In einem Dashboard eines BA Systems werden der Umsatz und die Preisentwicklung für die sieben Produkte einer Produktgruppe angezeigt. Bei fünf Produkten ist die Preis- und Umsatzentwicklung relativ konstant. Der Umsatz von Produkt 6 entwickelt sich im Vergleich zu dem von Produkt 7 rückläufig. Produkt 6 wird im Betrachtungszeitraum zu Produkt 7 relativ etwas teurer. Nun liegt die Visualisierung im der Schluss nahe, dass der höhere Preis den Umsatzrückgang rechtfertigt, also ursächlich dafür ist. Da in der Visualisierung des Dashboards keine weiteren Informationen vorhanden sind wird dieser Eindruck noch weiter verstärkt.

Diese Schlussfolgerung muss aber natürlich nicht zwingend wahr sein, denn beide Variablen – höherer Preis und Umsatzentwicklung – bedeuten zunächst einmal nichts Anderes als eine negative Korrelation: Je mehr Variable A (Preis), desto weniger Variable B (Umsatz). Eine Kausalität kann erst angenommen wenn bestimmte alternative Erklärungen ausgeschlossen werden.

Vividness (deutsch: Anschaulichkeit). Entscheidungsträger schätzen die Eintrittswahrscheinlichkeit eines Ereignisses höher ein, wenn sich das Ereignis leicht vorstellen lässt (Arnott 2006; Tversky und Kahneman 1974). Entscheidungsträger bevorzugen möglicherweise auch anschauliche Daten gegenüber unbedeutenden Daten und nehmen auffällige Merkmale von Objekten als wichtiger wahr (Farjoun und Lai 1997; Haley und Stumpf 1989). Das Verhalten von Verbrauchern im Kontext der Ausgestaltung von Versicherungen und Garantien bietet ein Beispiel für die Anschaulichkeitsverzerrung. Nach der Zustimmung zum Kauf eines Neuwagens wird den Verbrauchern in der Regel die Möglichkeit geboten, eine Garantieverlängerung zu erwerben. Der Verkäufer erklärt typischerweise, dass man für einige Dollar mehr pro Monat sich keine Gedanken bzgl. Reparaturen machen muss. (Tversky und Kahneman 1981) fragten sich warum fast die Hälfte der Neuwagenkäufer eine Garantieverlängerung erwirbt? Sie kamen basierend auf Dokumenten, die im Rahmen einer Klage gegen Nissan öffentlich wurden zu dem Schluss, dass es nicht daran liegt, dass es hierbei um ein gutes Geschäft für die Verbraucher handelt. Die typische Garantieverlängerung kostete 795 Dollar. Lediglich 131 Dollar flossen in die Deckung von Reparaturen, 109 Dollar gingen an Nissan für Verwaltungskosten, und die restlichen 555 Dollar gingen als Profit an den Händler. Es scheint, dass die Anschaulichkeit einer kostspieligen Reparatur viele

Verbraucher zu einer risikoscheuen Entscheidung veranlasst, die sie wahrscheinlich nicht treffen würden, wenn sie ihre Optionen sorgfältiger abwägen würden.

# Beispiele aus der Business Analytics Praxis

Ein Hersteller von produzierenden Maschinen bietet seinen Kunden eine Echtzeitüberwachung der verkauften Maschinen an und garantiert dafür den rechtzeitigen Austausch von Betriebsstoffen und Verschleißteilen. Die "Predictive Maintenance" Anwendung gab in ihrer ersten Version nur das Ergebnis aus, ob ein Teil gewechselt werden muss

# Umweltaspekte

Adjustment and anchoring (deutsch: Anpassung und Verankerung). Entscheidungsträger müssen häufig eine erste Schätzung der Werte kritischer Variablen vornehmen. Sobald neue Daten eingehen, werden diese Werte angepasst. In der Regel werden neue Daten nicht ausreichend berücksichtigt, und Anpassungen sind unzureichend (Schwenk 1984). Endgültige Werte sind gegenüber den anfänglichen Schätzungen verzerrt (Tversky und Kahneman 1974). In ihrer Demonstration von Anchoring baten (Tversky und Kahneman 1974) die Teilnehmer, den Prozentsatz der in den Vereinten Nationen vertretenen afrikanischen Länder zu schätzen. Für jeden Teilnehmer wurde eine Zufallszahl (erhalten durch Drehen eines Roulette-Rades, beobachtet durch den Teilnehmer) als Ausgangspunkt angegeben. Von dort aus wurden die Teilnehmer gebeten, anzugeben, ob die tatsächliche Menge höher oder niedriger als dieser Zufallswert war, und dann ihre beste Schätzung zu entwickeln. Die willkürlichen Werte aus dem Rouletterad hatten einen wesentlichen Einfluss auf die Schätzungen der Teilnehmer. Zum Beispiel lag der Median unter denjenigen, die mit der Zahl zehn vom Roulette-Rad begannen, bei 25 Prozent afrikanischer Länder in der UNO. Unter denjenigen, die mit der Zahl 65 vom Rad begannen, lag der Median bei 45 Prozent. Obwohl sich die Teilnehmer bewusst waren, dass der Anker zufällig und unabhängig von der Beurteilungsaufgabe war, hatte der Anker einen dramatischen Einfluss auf ihr Urteilsvermögen. Interessanterweise verringerte die Bezahlung der Teilnehmer nach ihrer Genauigkeit das Ausmaß des Ankereffekts nicht.

# Beispiele aus der Business Analytics Praxis

Ein Business Analytics System, das basierend auf verschieden Analystendaten die absoluten Werte genauso wie die Wachstumsraten für bestimmte Produktgruppen in verschieden Regionen bzw. Märkten angibt, ist abhängig von den Analystendaten, die regelmäßig aktualisiert werden. Kommt es wegen einem globalen Ereignis zu einer drastischen Änderung der Analystendaten und damit zu einer starken Änderung der Werte des BA Systems, besteht die Gefahr, dass die älteren Werte einen Anker bilden und die neuen Werte nur abgeschwächt für die weitere Planung verwendet werden. Dies kann dazu führen, dass der Markt als zu groß eingeschätzt wird und damit ein zu großer Absatz erwartet wird.

Availability (deutsch: Verfügbarkeit). Entscheidungsträger beurteilen die Wahrscheinlichkeit oder Häufigkeit von Ereignissen danach, wie einfach es ist, sich an Vorkommnisse dieses Ereignisses in der Vergangenheit zu erinnern. In vielen Fällen kann dies eine nützliche Methode zur Beurteilung von Ereignissen sein, da sich häufige Ereignisse leichter erinnern lassen. Die Verfügbarkeit von Ereignissen im Gedächtnis kann jedoch durch andere Faktoren beeinflusst werden. Jüngste oder lebhafte Ereignisse sind leichter zu erinnern, was zu verzerrten Beurteilungen der Wahrscheinlichkeiten aufgrund der Verfügbarkeit führt (Tversky und Kahneman 1974; Schwenk 1988). (Tversky und Kahneman 1974) untersuchen die Effekte der Verfügbarkeitsheuristik in einer Studie, in der den Teilnehmern Namenslisten bekannter Persönlichkeiten beider Geschlechter vorgelesen wurden. Einer Gruppe wurde eine Liste vorgelesen, in der die aufgeführten Frauen relativ berühmter waren als die aufgeführten Männer, aber die Liste enthielt insgesamt mehr Männernamen. Der anderen Gruppe wurde eine Liste vorgelesen, in der die aufgelisteten Männer relativ berühmter waren als die aufgelisteten Frauen, aber die Liste enthielt insgesamt mehr Frauennamen. Nachdem die Liste jeweils vorgelesen wurde, sollten die Teilnehmer beider Gruppen angeben, ob die Liste mehr Namen von Frauen oder Männern enthalte. In beiden Gruppen vermuteten die Teilnehmer fälschlicherweise, dass das Geschlecht, das die relativ berühmteren Persönlichkeiten enthielt, das zahlreichere war. Die Teilnehmer hielten sich offenbar mehr an anschauliche Familiennamen als an weniger bekannte Persönlichkeiten.

# Beispiele aus der Business Analytics Praxis

Im Rahmen der Leistungsbeurteilung von Mitarbeitern können kognitive Verzerrungen, die aus der Verfügbarkeitsheuristik resultieren, auftreten. Unvollständige Daten bzgl. der Leistung des Mitarbeiters aus dem Reportingsystem (entweder positiv oder negativ) werden in der Leistungsbeurteilung stärker gewichtet weil sie präsenter sind als die alltägliche Mitarbeiterperformance. Die Aktualität der Ereignisse ist ebenfalls ein Faktor: Es besteht die Gefahr, dass die Mitarbeiterperformance unmittelbar vor der Beurteilung stärker gewichtet wird als die Performance zu Beginn des Beurteilungszeitraums.

Escalating commitment (deutsch: Eskalierendes Engagement). Viele kritische Managemententscheidungen betreffen eher eine Reihe von Entscheidungen als eine isolierte Entscheidung. Manager sind anfällig für eine bestimmte Art der Voreingenommenheit, wenn wir Entscheidungen seriell angehen - eine Tendenz zur Eskalation des Engagements für unsere ursprüngliche Entscheidung. Nachdem eine beträchtliche Menge an Ressourcen für ein Projekt gebunden wurde, fühlen sich die Entscheidungsträger für das Projekt verantwortlich und tendieren dazu, dem Projekt mehr Ressourcen zuzuweisen, als es objektiv sinnvoll wäre (Schwenk 1985; Staw 1981). Als Beispiel, begann 1966 ein Projekt zum Bau eines Kernkraftwerks in Long Island, New York. Man ging davon aus, dass es 75 Millionen Dollar kosten und bis 1973 in der Lage sein würde, Strom für die wachsende Stadt zu erzeugen. Niemand rechnete mit der Ablehnung der lokalen Bevölkerung. Insbesondere wegen dieses Widerstands wurde das Projekt erst 1986 zu einem Preis von mehr als 6 Milliarden Dollar fertiggestellt. Letztendlich wurde das Werk nie eröffnet (Barbour et al. 1992). Die Eskalation des Engagements könnte einer der Gründe gewesen sein, dass das Management der

Long Island Lighting Company trotz der stark steigenden Kosten und der Verzögerung um zwei Jahrzehnte bereit war, so lange an ihrem Projekt festzuhalten.

# Beispiele aus der Business Analytics Praxis

Nachdem der Beschluss ein neues BA-System zur Vorhersage von Absatzzahlen für bestimmte Produktgruppen in bestimmten Märkten vom Management gegen viel internen Wiederstand durchgesetzt wurde und unter hohem Ressourcenaufwand durchgeführt wurde, besteht die Gefahr den Vorhersagen des Systems zu viel Gewicht zuzuschreiben auch wenn es nach objektiven Maßstäben nicht die erwartete Leistungsfähigkeit erbringt.

Hindsight (deutsch: Rückschau). Der Hindsight Bias führt dazu, dass Entscheidungsträger die Vorhersehbarkeit vergangener Ereignisse überschätzen (Schwenk, 1988). Nachdem ein Ereignis eingetreten ist, glauben Menschen, dass sein Ausgang vorhersehbar gewesen sei. Dies kann Entscheidungsträger dazu veranlassen, sich auf bestimmte Faktoren zu konzentrieren, von denen angenommen wird, dass sie das Ergebnis verursacht haben. In einem anschließenden Planungsprozess können sie dem erneuten Auftreten dieses Ereignisses eine ungerechtfertigt hohe Wahrscheinlichkeit zuweisen (Barnes, 1984). Verzerrte Interpretationen vergangener Ereignisse können auch dazu führen, dass Planungsprozesse unangemessen verändert werden (Bukszar und Connolly 1988). Als Beispiel erwarteten vor der Finanzkrise im Jahr 2008 viele Analysten eine positive konjunkturelle Entwicklung und weiter steigende Aktienkurse. Nach der Krise lag der Anteil derjenigen Analysten, die der Meinung waren, dass eine solche Finanzkrise aufgrund von bspw. zu lockeren Eigenkapitalvorschriften für Banken zu erwarten gewesen wäre, deutlich über dem Anteil der mahnenden Analysten vor der Krise. Heute würden mehr Analysten bei ähnlichen Anzeichen, eine weitere Finanzkrise erwarten, obwohl ein weiteres Auftreten nicht nur von diesen wenigen Faktoren abhängt, sondern multifaktoriell ist (Dobelli 2018).

#### Beispiele aus der Business Analytics Praxis

Ein Hersteller von Produktionsanlagen verbessert seinen Vertriebserfolg dadurch, dass er passgenaue Rückkaufangebote bereits beim Verkauf unterbreitet. Hierfür ist eine Prognose der Nutzungsart der Maschine beim Kunden notwendig. Dieses basiert auf Sensordaten bei sich im Betrieb befindende Maschinen. Wenn sich wegen bspw. unerwarteter Nachfrageentwicklung die Nutzungsart von der erwarteten Nutzung abweicht, kann es zu einem überhöhten Rückkaufangebot kommen.

# 2.3.3 Katalog validierter Biases (kognitiver Verzerrungen) bei der datengetriebenen Entscheidungsfindung

Im Nachfolgenden werden die im Katalog erfassten kognitiven Verzerrungen zusammenfassend dargestellt. Neben einer Kurzbeschreibung wurden zudem mögliche Fragestellungen auf Basis der Praxisbeispiele formuliert, die einen Aktionsrahmen aufspannen, um das Auftreten des jeweiligen Bias in der unternehmerischen Praxis im Kontext von Business Analytics zu vermeiden. Neben diesen Fragestellungen erfolgt

eine Übersicht über übergeordnete und validierte Methoden zur Vermeidung kognitiver Verzerrungen, in Kapitel 4.4.

Bias	Kurzbeschreibung	Mögliche Fragestellung zur Vermeidung des Bias in der BA-Praxis	
Soziale Aspekte			
Illusion of Control	Tendenz die eigenen Fähigkeiten im Hinblick auf die Bewältigung künftiger Ereignisse zu überschätzen	<ul> <li>Stehen interne Daten zur Verfügung, die eine systematische Analyse (unternehmens-)eigener Fähigkeiten zulassen?</li> <li>Sind die Einflussfaktoren auf die herausgearbeiteten (unternehmens-)eigenen Fähigkeiten bekannt?</li> <li>Sind Prognosen zu zukünftigen Entwicklungen vollständig und lassen einen Abgleich mit den eigenen Fähigkeiten zu?</li> </ul>	
Overcon- fidence	Selbstüberschätzung bzw. Fehleinschätzung der eigenen Fähigkei- ten	<ul> <li>Werden bei Prognosen oder Szenario- analysen zugrundeliegende Annahmen hervorgehoben?</li> <li>Werden Konfidenzintervalle mit Analysen bereitgestellt?</li> <li>Müssen Entscheidungen auf Basis daten- getriebener Ergebnisse schriftlich be- gründet werden (Wie sicher ist sich der Entscheidungsträger? Warum?)?</li> </ul>	
Overopti- mism	Einschätzung der Eintrittswahrscheinlichkeit eines Ereignisses liegt höher, als sie objektiv tatsächlich ist	<ul> <li>Werden bei Prognosen oder Szenario- analysen zugrundeliegende Annahmen hervorgehoben?</li> <li>Müssen Entscheidungen auf Basis daten- getriebener Ergebnisse schriftlich be- gründet werden (Wie sicher ist sich der Entscheidungsträger? Warum?)?</li> </ul>	
Preferred alternati- ves	Neigung anstatt alle entscheidungsrelevan- ten Ziele in Betracht zu ziehen, sich nur auf ei- nen Wert oder ein Ziel zu konzentrieren	<ul> <li>Besteht ein systematisches Vorgehen, welches unter anderem die schriftliche Bewertung aller Entscheidungsalternativen vorsieht, bei Auswahl von Alternativen?</li> <li>Erhalten alle Alternativen die im Rahmen von Analysen vermittelt werden den gleichen Raum?</li> </ul>	
Reasoning by analogy	Neigung Analogien zu nutzen, die objektiv nicht sinnvoll sind und somit wichtige Informa- tionen zu übersehen.	<ul> <li>Werden datengetriebene Ergebnisse bereits bei der Erstellung mit passenden verschriftlichten Analogien versehen?</li> <li>Erfassen diese Analogien alle Informationen, aber können dennoch den Sachverhalt einfacher erläutern?</li> </ul>	

Recollec- tion	Verzerrte Wahrneh- mung von Erinnerun- gen an bestimmte Situ- ation	<ul> <li>Stehen historische Daten im Unterneh- men zur Verfügung? Werden diese syste- matisch kategorisiert und aktuellen Ent- scheidungsgrundlagen nach Passung an- gefügt?</li> </ul>
Selective perception	Die Erwartungen bezüglich einer Situation verzerren sowohl die für relevant befundenen Informationen als auch mögliche Beobachtungen.	<ul> <li>Erfolgt die Erstellung datengetriebener Ergebnisse einem systematischen und replizierbaren Vorgehen?</li> <li>Werden datengetriebenen Ergebnissen Erklärungen bezüglich der Methodik ins- besondere der Stichprobenauswahl an- gehängt?</li> </ul>
Self-attri- bution	Übermäßigen Vertrau- ens in das eigene Ur- teilsvermögen	<ul> <li>Müssen Entscheidungen auf Basis daten- getriebener Ergebnisse schriftlich be- gründet werden (Wie sicher ist sich der Entscheidungsträger? Warum?)?</li> </ul>
Status quo	Bevorzugen der aktuellen Situation bzw. die Präferenz, dass alles so bleibt, wie es ist. Wandel wird negativ wahrgenommen	<ul> <li>Werden Übersichten bzw. historische Daten über vergangene Entscheidungen erstellt und meta-analytisch bewertet?</li> <li>Werden Reports in regelmäßigem Turnus einer Überarbeitung auf Basis von Feedbackschleifen mit Entscheidungsträgern unterworfen?</li> </ul>
Technische	Aspekte	
Devalua- tion of par- tially de- scribed al- ternatives	Negativere Bewertung von weniger Ausführ- lich beschriebenen Handlungsalternativen.	<ul> <li>Erhalten alle Alternativen die im Rahmen von Analysen vermittelt werden den gleichen Raum?</li> <li>Werden Beschreibungs- und Darstellungsalternativen für datengetriebene Ergebnisse geprüft und im Rahmen von Feedbackschleifen bewertet?</li> </ul>
Framing	Verhalten eines Emp- fängers wird von der Präsentation einer In- formation beeinflusst (bspw. positiv oder ne- gativ)	<ul> <li>Werden Analysen auf mehrere Arten dargestellt um eine Beeinflussung durch die Darstellung zu minimieren? Werden beispielsweise schriftliche Erklärungen zu Grafiken gegeben?</li> <li>Werden bei der Erstellung von Analysen positive und negative Darstellungsformen in Erwägung gezogen?</li> </ul>
Law of small num- bers	Überschätzung der Bedeutung kleiner Stichproben	<ul> <li>Wird die Größe der Stichprobe, auf der datengetriebene Ergebnisse basieren, mitangegeben? Erfolgt beispielsweise Analogiebildung um die Größe der Stich- probe bzw. der zugrundeliegenden Daten begreifbar zu machen?</li> </ul>

		Werden mögliche statistische Verzerrun- gen bei der Stichprobenauswahl klar kommuniziert?
Miscon- ceptions of chance	Überschätzung der Bedeutung einer Reihe ähnlicher Ereignisse	<ul> <li>Werden historische Daten nur für eingeschränkte Zeiträume präsentiert?</li> <li>Ist die Granularität datengetriebener Ergebnisse ausreichend um Varianz zwischen den Ergebnissen ausreichend bestimmen zu können?</li> </ul>
Redun- dancy	Überhöhtes Vertrauen in die Genauigkeit und Bedeutung redundanter, voluminöser Daten	<ul> <li>Wird die Größe der Stichprobe, auf der datengetriebene Ergebnisse basieren, mitangegeben?</li> <li>Erfolgt beispielsweise Analogiebildung um die Größe der Stichprobe bzw. der zugrundeliegenden Daten begreifbar zu machen?</li> </ul>
Represen- tativeness	Überschätzung des Ausmaß, in dem eine Situation oder eine Stichprobe repräsenta- tiv für die Situation o- der Population ist, auf die verallgemeinert werden soll	<ul> <li>Werden mögliche statistische Verzerrungen bei der Stichprobenauswahl klar kommuniziert?</li> <li>Erfolgt eine regelmäßige Schulung von Entscheidungsträgern hinsichtlich Stichprobenauswahl?</li> </ul>
Satisficing	Tendenz die Suche nach Informationen vorzeitig abzubrechen, wenn eine (zu) großen Datenmenge vorliegt	<ul> <li>Erfolgt die Erstellung datengetriebener Ergebnisse einem systematischen und replizierbaren Vorgehen?</li> <li>Werden datengetriebenen Ergebnissen Erklärungen bezüglich der Methodik ins- besondere der Stichprobenauswahl an- gehängt?</li> </ul>
Statistical miscon- ceptions	Fehleinschätzung verschiedener auf statistischer Zusammenhänge	Erfolgt eine regelmäßige Schulung von Entscheidungsträgern hinsichtlich statisti- scher Zusammenhänge?
Vividness	Einschätzung der Eintrittswahrscheinlichkeit eines Ereignisses liegt höher, wenn sich das Ereignis leicht vorstellen lässt	<ul> <li>Werden datengetriebene Ergebnisse bereits bei der Erstellung mit passenden verschriftlichten Analogien versehen?</li> <li>Wird bei der Darstellung datengetriebener Ergebnisse auf Gleichförmigkeit zwischen verschiedenen Analysen geachtet?</li> </ul>

Umweltaspe	ekte		
Adjust- ment and anchoring	Schätzung eines numerischen Wertes basierend auf einer Initialinformation (Anker), welche für die Schätzung ungenügend angepasst wird	<ul> <li>Werden Analysen bzw. daraus entste hende Reports immer in der gleichen Rehenfolge vermittelt? Lässt sich die Rehenfolge eventuell randomisieren?</li> <li>Wird auf mögliche Verzerrungen die sich aus der Reihenfolge von Analysen ergeben in Reports hingewiesen?</li> </ul>	ei- ei- ch
Availability	Beurteilungen über die Wahrscheinlichkeit ei- nes Ereignisses wer- den nur anhand bereits zur Verfügung stehen- der Information abge- leitet	<ul> <li>Werden Übersichten bzw. historische Daten über vergangene Entscheidungen estellt und meta-analytisch bewertet?</li> <li>Werden Reports in regelmäßigen Turnuangepasst oder basieren diese immer ander gleichen Informationsbasis?</li> </ul>	er- us
Escalating commit-ment	Festhalten an Ent- scheidungen, obwohl diese sich als negativ erweisen	<ul> <li>Lässt Entscheidungskultur im Unternel men Raum für Fehler?</li> </ul>	h-
Hindsight	Neigung, die Vorher- sehbarkeit eines Ereig- nisses zu überschät- zen, nachdem dieses eingetreten ist	<ul> <li>Werden Übersichten bzw. historisch Daten über vergangene Entscheidunge erstellt und meta-analytisch bewertet?</li> </ul>	_
Recollec- tion	Neigung, vergangene Strategien als rationa- ler/logischer in Erinne- rung zu rufen, als sie es waren	<ul> <li>Wird der Erfolg/Misserfolg vergangene Entscheidungen evaluiert und im Ral men von Reports diskutiert?</li> <li>Werden Übersichten bzw. historische Daten über vergangene Entscheidungen estellt und meta-analytisch bewertet?</li> </ul>	h- a-

#### 2.3.4 Fazit zu Arbeitspaket 3

In Arbeitspaket 3 wurden im Rahmen einer systematischen Literaturrecherche und einer Analyse von Situationsbeschreibungen die im Rahmen von zwei Workshops, einer Umfrage und mehreren Experteninterviews erhoben wurden, kognitive Verzerrungen (Bias) die im Kontext von BA-Entscheidungen in Erscheinung treten können identifiziert, bewertet, in einem Katalog zusammengefasst und mit Praxisbeispielen angereichert. Die im Katalog erfassten kognitiven Verzerrungen und Beispiele wurden zudem auszugsweise in zwei Online-Workshops validiert. Der entstandene Katalog gibt Unternehmen einen umfassenden Überblick über kognitive Verzerrungen im BA-Kontext und ermöglicht die systematische Auseinandersetzung mit dem Thema und den daraus entstehenden Problemen in der Entscheidungsfindung. Vor diesem Hintergrund, wird in Arbeitspaket 4 ein Aktionsrahmen für Unternehmen, mit Gegenmaßnahmen für kognitiven Verzerrungen und akzeptanzsteigernden Maßnahmen, vorgestellt.

#### 2.4 Arbeitspaket 4

Das Arbeitspaket 4 "Ableiten von Maßnahmen zur Steigerung der Akzeptanz und Reduktion von Biases" dient der Identifikation von Maßnahmen in den Unternehmen zur Steigerung der Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse sowie zur Reduktion von Biases.

Durchgeführte Arbeiten	Erzielte Ergebnisse
Literaturreview zu <b>Erklärungsmethoden</b> , die zu einer transparenten und differenzierte Betrachtung der Ergebnisse von Business Analytics ermöglichen.	<ul> <li>Identifikation von Erklärungsmethoden zur Steigerung der Akzeptanz von Business Analytics im Rahmen einer systematischen Literaturanalyse.</li> <li>Kategorisierung in eine Taxonomie von 24 Erklärungsmethoden die die Akzeptanz von Business Analytics Erkenntnissen steigern können.</li> </ul>
Durchführung einer Vignettenstudie zur Validierung der identifizierten Erklä- rungsmethoden und Messung des Ein- flusses auf die Akzeptanz.	<ul> <li>Durchführung einer Vignettenstudie zur Validierung der identifizierten Erklärungsmethoden und zur Messung des Einflusses auf die Akzeptanz mit 222 Probanden.</li> <li>Ableitung von theoretischen Erkenntnissen und praktischen Handlungsempfehlungen zum Einsatz von Erklärungsmethoden auf Basis statistischer Auswertungen.</li> </ul>
Gegenüberstellung der Ergebnisse und Validierung durch Interviews mit Experten aus der Psychologie.	<ul> <li>Gegenüberstellung der Ergeb- nisse und Interviews mit Experten aus der Psychologie.</li> </ul>

# 2.4.1 Erklärungsmethoden für algorithmische Systeme

In AP4 wurden zunächst Erklärungsmethoden, die einen Einfluss auf die Akzeptanz von BA haben ermittelt. Eine Auswahl dieser Erklärungsmethoden wurde auf ihre Wirkungsweise (z. B. Erhöhung der Transparenz) in einer Vignettenstudie untersucht.

Die Verständlichkeit statistischer Modelle und Modelle des maschinellen Lernens wird als ein wichtiger Faktor für die Akzeptanz von Business Analytics (BA) erachtet (Martens und Provost 2014). Während einige BA-Systeme dem Nutzer die Möglichkeit bieten, die dem BA-System und seinen Analysen zugrundeliegenden Annahmen oder Einschränkungen zu verstehen (Shollo und Galliers 2016), sind komplexere Systeme oftmals unverständlich (Breiman 2001). Die oft als "Black-Box"-Algorithmen bezeich-

neten Algorithmen sind leistungsfähige Prognosewerkzeuge. Jedoch müssen Entscheidungsträger auch in der Lage sein, diese "Black-Box"-Algorithmen zu verstehen, um Vertrauen zu entwickeln und anschließend die Systeme zur Entscheidungsfindung einzusetzen (Martens und Provost 2014).

In der Literatur sind Anhaltspunkte für Erklärungen bekannt, mit denen die Akzeptanz von Algorithmen bzw. datengetriebenen Ergebnissen gesteigert werden kann. Z. B. wurden in der Literatur zu Entscheidungsunterstützungssystemen (engl. Decision Support Systems [DSS]) Erklärungen schon frühzeitig als ein notwendiges Mittel identifiziert, um die Akzeptanz der DSS-Anwender zu fördern (Lilien et al. 2004). Auch die Forschung im Bereich der wissensbasierten Systeme (engl. Knowledge Based Systems [KBS]) hat gezeigt, dass Erklärungen, welche zusätzlich zu den Empfehlungen des Systems gegeben werden, dazu beitragen können, Vorbehalte zu überwinden, die Nutzer gegenüber der Zuverlässigkeit eines Systems und seiner Empfehlungen haben (Dhaliwal und Benbasat 1996; Gregor 1999). Indem die Entscheidungsprozesse eines Systems erläutert werden, wird auch seine wahrgenommene Zuverlässigkeit erhöht. Dies wiederum gibt dem Nutzer die Möglichkeit, die Verarbeitung der Daten zu verstehen, was zu einer erhöhten Akzeptanz (Ye und Johnson 1995) und einem höheren Vertrauen führen kann (Moa und Benbasat 2000). Darüber hinaus können Erklärungen auch zu einer effektiveren Beeinflussung der Überzeugungen des Benutzers durch die Empfehlungen von KBS führen (Ye und Johnson 1995). In späteren Untersuchungen über Empfehlungssysteme zeigten die Autoren Wang und Benbasat (2007), dass verschiedene Arten von Erklärungen das Vertrauen in die Empfehlung eines Systems erhöhen können.

#### Systematische Literaturrecherche

Vor dem Hintergrund der bestehenden Literatur im Bereich DSS und KBS, wurde zunächst eine systematische Literaturrecherche durchgeführt, um Erklärungsmethoden für den Einsatz im Kontext von BA zu erfassen und zu kategorisieren.

Für die systematische Literaturrecherche wird der Schlüsselbegriff "Erklärung" mit relevanten Begriffen im Kontext der Erklärungsmethoden kombiniert. Erklärungsmethoden werden hauptsächlich im Bereich der DSS, KBS, Expertsystems und Recommender Systems verwendet. Nach dem Literaturreview von Chen et al. (2012) ist Decision Support ein häufig verwendeter Begriff in der Forschung zu Business Intelligence und Analytics. KBS und Expertsystems können als Unterbegriffe von DSS verstanden werden (Hosack et al. 2012). Recommender Systems passen ebenfalls in diesen Bereich, da Empfehlungen aus großen Datenmengen eines der Versprechen von Business Analytics sind (Chen et al. 2012). Daher werden diese vier Begriffe in den Suchstring aufgenommen. Da Recommender manchmal anstelle von Recommender System verwendet wird, wird dieser Begriff in der gekürzten Version verwendet. Darüber hinaus wird Recommendation in den Suchstring eingefügt, um alle möglichen Variationen ein-

zuschließen. Außerdem wird die Abkürzungen DSS und KBS in den Suchstring eingefügt. Zudem umfasst der Suchstring Vertrauen und Akzeptanz. Diese beiden Konstrukte sollen durch den Einsatz von Erklärungsmethoden beeinflusst werden. Da einer der wesentlichen Gründe, der zur Business Analytics Nutzung bewegt, die Entscheidungsfindung ist, wird dieser Begriff auch inkludiert (Chen et al. 2012).

Für die Suche nach wird die Suche auf Beiträge aus folgenden Zeitschriften eingeschränkt: Information Systems Research, MISQ, Journal of Management Information Systems, Journal of the Association for Information Systems, Information Systems Journal, European Journal of Information Systems, The Journal of Strategic Information Systems, Decision Support Systems (DSS), Decision Sciences, Expert Systems with Applications, Knowledge-based Systems und International Journal of Human-Computer Studies. Diese Einschränkung stellt zudem sicher, dass nur Aufsätze, die einem Peer-Review unterzogen wurden, berücksichtigt werden. IEEE Explore wird durchsucht, um auch Konferenzprotokolle zu berücksichtigen, die zusätzlich relevante Informationen enthalten können (Webster und Watson 2002c).

Beide Datenbanken werden nach Artikeln durchsucht, deren Titel, Schlüsselbegriffe oder Abstracts mit dem oben beschriebenen Suchstring übereinstimmen. Diese Suche ergibt insgesamt 630 Artikel. Um alle irrelevanten Artikel herauszufiltern, werden Einund Ausschlusskriterien eingeführt. Relevant für die Beantwortung der Forschungsfragen sind Beiträge, die sich mit Erklärungsmethoden im Bereich Information Systems oder verwandten Bereichen befassen. Daher werden alle Abstracts auf die Erfüllung dieses Einschlusskriteriums überprüft. Durch diesen Schritt reduziert sich die Zahl der Artikel auf 151. Anschließend werden diese Artikel auf Ausschlusskriterien (AK) geprüft, indem der komplette Text analysiert wird. Zunächst müssen die Artikel in englischer Sprache verfasst sein (AK1). Zweitens müssen die Aufsätze ihren Schwerpunkt auf Erklärungsmethoden legen (AK2). Dies ist notwendig, da einige Aufsätze Systeme beschreiben, die zwar Erklärungen nutzen, aber ihre Forschung auf andere Bereiche konzentrierten, ohne diese Erklärungsmethoden und ihre Auswirkungen tatsächlich zu untersuchen. Da das Hauptziel dieser systematischen Literaturrecherche darin besteht, verschiedene Erklärungsmethoden zu extrahieren und zu kategorisieren, werden auch Aufsätze, die keine oder keine detaillierte Beschreibung der verwendeten Erklärungen geben, ausgeschlossen (AK3). Zuletzt werden Artikel, die die Auswirkungen von Erklärungen auf den Nutzer des Systems nicht empirisch untersuchen, aus der Literaturbasis entfernt (AK4).

Diese Filterschritte führen zu insgesamt 25 Artikeln, die auf der Grundlage der anfänglichen Datenbankrecherche ausgewählt werden. Eine detaillierte Aufschlüsselung der Auswirkung des Einschlusskriteriums und der Ausschlusskriterien ist in Anhang AP4 Anhang aufgeführt. Um sicherzustellen, dass alle relevanten Artikel in die Literaturanalyse einbezogen werden können, empfehlen Webster und Watson (2002), eine Vorwärts- und Rückwärtssuche auf der Grundlage, der in der Datenbankrecherche identifizierten Literatur, durchzuführen. Während bei einer Rückwärtssuche die Zitate

der ausgewählten Aufsätze analysiert werden, um weitere relevante Artikel zu identifizieren, wird bei der Vorwärtssuche die Suchumgebung "Web of Science" verwendet, um Aufsätze zu finden, welche die zuvor ausgewählte Literatur zitieren (Webster und Watson 2002c). Dieser Empfehlung folgend wurden weitere 19 relevante Artikel identifiziert, die die oben genannten Kriterien erfüllen. Daraus ergibt sich eine Gesamtzahl von 44 Artikel, welche im nächsten Schritt im Detail ausgewertet werden.

Die Erklärungsmethoden werden dabei nach dem Inhalt der Erklärung klassifiziert, welche meist auf dem Problemlösungsverhalten des Systems beruht (Chandrasekaran et al. 1989). In der Tabelle in

Anhang werden die gefundenen Erklärungsmethoden und die jeweiligen Quellen detailliert aufgeführt. Da einige Erklärungsmethoden von verschiedenen Autoren unterschiedlich benannt wurden, werden die gebräuchlichsten Bezeichnungen zur Beschreibung der Methoden in der ersten Spalte beschrieben.

# Morphologischer Kasten zur Systematisierung von Erklärungsmethoden

Die Erklärungsmethoden werden ferner hinsichtlich ihrer Auswirkungen auf das Verhalten und die Wahrnehmung des Systems durch den Benutzer analysiert und in einem morphologischen Kasten zusammengefasst. Erklärungsmethoden unterscheiden sich dabei bezüglich ihres positiven Einflusses auf die die Akzeptanz der Ergebnisse des Systems und auf die Wahrnehmung des Systems, die Verständlichkeit des Systems, das Vertrauen in das System, die Problemlösungsfähigkeit, die durch das System gegeben wird, und die wahrgenommene Qualität der Entscheidung des Benutzers sowie die Zufriedenheit des Nutzers mit der Entscheidung.

	Erklärungsmethode h	nat einen posi	tiven Einfluss	auf	
Erklärungsmethode	die Akzeptanz der Ergebnisse des Systems und auf die Wahrnehmung des Systems	die Verständlichkeit des Systems	trauen in	die Problemlö- sungsfä- higkeit	die wahrge- nommene Qualität der Entscheidung sowie Zufrieden- heit mit der Ent- scheidung
Justification	Х	х	х	х	Х
Rule Trace	X	х	х	х	
Strategic	Х	х			
Tradeoff	Х	х	х		Х
Neighbor Style	Х	х	х		
Definition	Х			х	
Confidence		х		х	
Social	Х		х		Х
Feature	Х		х	х	Х
Tag		х		х	Х
Influence		х	х	х	Х
Algorithm		х	х		
Procedural				х	_
Directive		· · · · · · · · · · · · · · · · · · ·		х	
Why not		Х			_

#### Katalog von Erklärungsmethoden

Im Folgenden wird ein Auszug der ermittelten Erklärungsmethoden genauer beschrieben. In Abstimmung mit Mitgliedern des projektbegleitenden Ausschusses wurden fünf Erklärungsmethoden als besonders interessant befunden und für eine experimentelle Untersuchung im Rahmen einer Vignettenstudie ausgewählt. Dementsprechend werden nachfolgend ausschließlich die ausgewählten Erklärungsmethoden vorgestellt und bespielhaft in Tabelle 7 dargestellt. Die restlichen Erklärungsmethoden aus dem gebildeten Erklärungsmethodenkatalog werden in Anhang aufgeführt. Aus der Literatur entnommene Beispiele für die Umsetzung der einzelnen Erklärungsmethoden sind in Anhang dargestellt.

Unter allen analysierten Aufsätzen ist **Justification** die am häufigsten verwendete Erklärungsmethode. Justification Erklärungen wurden durch Swartout's (1983) Expertensystem "XPLAIN" eingeführt und rechtfertigen die "zugrundeliegenden Gründe für einen Zustand oder eine Handlung" eines Systems (Dhaliwal und Benbasat 1996). Sie werden als Feedbackerklärungen verwendet und rechtfertigen die Bedeutung des Outputs des Systems (Dhaliwal und Benbasat 1996), z.B. indem sie ihn mit dem Domänenwissen verknüpfen, welches im Entscheidungsprozess des Systems verwendet wurde (Chandrasekaran et al. 1989). Darüber hinaus werden sie verwendet, um mögliche Konsequenzen des ermittelten Ergebnisses zu erklären (Dhaliwal und Benbasat 1996; Mao und Benbasat 2001). Diese Erläuterungen können auch verwendet werden, um die Eingabeaufforderung der Systeme gegenüber dem Benutzer zu begründen, indem die Bedeutung der angeforderten Daten für die folgenden Auswertungen oder Prozesse aufgezeigt werden (Dhaliwal und Benbasat 1996). Eines der Hauptmerkmale dieser Erklärungsmethode besteht darin, dass sie auf der Grundlage vorhandener Informationen in der Wissensbasis zusammengestellt werden kann, manchmal sogar, bevor das System irgendeine Prozedur durchgeführt hat (Chandrasekaran et al. 1989). Vereinfacht ausgedrückt, liefern Justification Erklärungen eine Antwort auf die Frage "Warum [...]?"(Gönül et al. 2006). Alle analysierten Rechtfertigungserklärungen werden in einer natürlichen Sprache präsentiert und sind textbasiert. Sie werden entweder automatisch bereitgestellt, indem sie unmittelbar neben dem Ergebnis angezeigt werden (Gönül et al. 2006; Li und Gregor 2011), oder auf Wunsch des Benutzers. Dieser Benutzeraufruf erfolgt über Schaltflächen, zum Beispiel mit der Beschriftung "Warum" (Mao und Benbasat 2001) oder in Form von Hyperlinks (Arnold et al. 2004). Dies kann bspw. auf der Nutzeroberfläche des Ausgabebereichs einer Analytics Anwendung realisiert werden

Rule Trace ist die am zweithäufigsten verwendete Erklärungsmethode. Sie wurde wie Justification durch das XPLAIN-System von (Swartout 1983) eingeführt. Rule Trace oder Line of Reasoning-Erklärungen liefern eine Beschreibung, wie das System sein Ergebnis erzielt hat, indem sie aufzeigen, auf welchen Daten das Ergebnis beruht oder welche Regeln verwendet oder befolgt wurden (Chandrasekaran et al. 1989). Die Eingabewerte können im Rahmen der Erklärung bspw. in Bezug zu den Perzentilen des gesamten Datensatzes für den bestimmten Parameter gesetzt werden und somit eine

Indikation liefern, wie das System entschieden hat. Dies gibt wiederum Aufschluss über die Bewertungen und Entscheidungen, die das System getroffen hat, um das Ergebnis zu erreichen (Mao und Benbasat 2001). Als Feedforward-Erklärungen können sie angeben, wie der Input vom System verwendet wird und welche Regeln angewendet werden (Dhaliwal und Benbasat 1996). Da Rule Trace-Erklärungen hauptsächlich auf dem Vorgehen des Systems basieren, können sie nicht immer vorab kompiliert werden (Chandrasekaran et al. 1989). In anderen Worten: Rule Trace-Erklärungen beantworten die Frage "Wie [...] ?" (Mao und Benbasat 2001). In den meisten Studien wurden Rule Trace-Erklärungen in Textform und in natürlicher Sprache formuliert. Nur wenige Wissenschaftler haben eine multimediale Form der Erklärungsmethode untersucht. Ein System zur Analyse und dem Monitoring der Cyber Security Vorfällen von Ehrlich et al. (2011) zum Beispiel nutzte Grafiken, mit deren Hilfe das System einen Sicherheitsvorfall kommunizieren konnte. Das Empfehlungssystem von Tan et al. (2012) präsentierte neben dem empfohlenen Element auch Sternebewertungen, die angeben, wie gut die Attribute des Elements den Präferenzen des Benutzers entsprechen. Rule Trace-Erklärungen werden entweder automatisch neben den Ergebnissen des Systems dargestellt (Bussone et al. 2015) oder auf Wunsch des Benutzers angezeigt. Der Aufruf durch den Benutzer kann z.B. durch einen Klick auf einen Button mit der Aufschrift "Wie" (Wang et al. 2016), durch Hyperlinks (Arnold et al. 2006) oder durch die Auswahl eines bestimmten Klassifikationsergebnisses (Ehrlich et al. 2011) erfolgen.

Strategic Erklärungen stellen die zugrundeliegende Strategie dar, indem sie den Problemlösungsansatz des Systems beschreiben (Chandrasekaran et al. 1989; Dhaliwal und Benbasat 1996) und zudem beschreiben, wie dieses spezielle Ergebnis oder der angeforderte Input, wenn er als Feedforward-Erklärung verwendet wird, in das Gesamtziel des Systems passt (Dhaliwal und Benbasat 1996). Strategische Erklärungen wurden erstmals mit dem Expertensystem "NEOMYCIN" von Clancey (1983) eingeführt. Dabei entschieden sich fast alle Wissenschaftler für eine textuelle Darstellungsform, d. h. die Erklärungen wurden in natürlicher Sprache verfasst. Ausgenommen sind hier die Autoren (Tan et al. 2012). Die Autoren verwenden eine Sternenbewertung, um die mögliche Übereinstimmung des empfohlenen Elements anzuzeigen. Sie begründen diese Art der Darstellung damit, dass das Hauptziel des Systems darin besteht, das am besten übereinstimmende Element für den Benutzer zu empfehlen und deshalb das System die voraussichtliche Übereinstimmung anzeigt. Kaptein et al. (2017) haben einem humanoiden Roboter so programmiert, dass dieser sich verbal erklären kann, um Kindern ohne Lesefähigkeit die Möglichkeit zu geben seinen Ausführungen zu folgen. Das Empfehlungssystem von Tan et al. (2012) und der Roboter von Kaptein et al. (2017) waren die einzigen Fälle, in denen die strategischen Erklärungen automatisch neben der Empfehlung präsentiert wurden. In allen anderen Systemen werden die strategischen Erklärungen erst dann präsentiert, wenn ein Benutzer sie angefordert hat, z.B. durch Anklicken eines Hyperlinks mit dem Text "Strategie des Problemlösungsansatz" (Arnold et al. 2004).

Influence Erklärungen zeigen den Einfluss von Attributen, Modellmerkmalen oder bereits bewerteten Elementen auf das aktuelle Ergebnis oder die Empfehlung an (Bilgic und Mooney 2005a). Alle gefundenen Artikel zu dieser Erklärungsmethode lieferten die Erklärung automatisch zusammen mit dem Ergebnis des Systems. Bilgic und Mooney (2005a) verwendeten sie, um ihre Empfehlung für Bücher zu erläutern. Neben der Empfehlung zeigten sie eine Tabelle, in der sie frühere Bücher aufführten, die vom Benutzer bewertet wurden und die die Empfehlung des Systems verursachten. Neben dem Namen der Bücher zeigten sie die Bewertung des Benutzers und den Einfluss dieser Bewertung auf das aktuelle Ergebnis durch eine Zahl zwischen 0 und 100 an, wobei 100 den höchsten Einfluss darstellt. In der Studie von Lai und Tan (2019) hatten die Teilnehmer die Aufgabe, zu beurteilen, ob eine Hotelbewertung echt oder irreführend war. Zusätzlich zur Klassifizierung hebt das System zehn Wörter in der Bewertung mit blauer Farbe hervor, um zu veranschaulichen, welche Wörter den größten Einfluss auf das Machine Learning Modell hatten. Die Farbstärke der Hervorhebung wurde nach und nach entsprechend einer Heatmap verteilt, die über der Rezension angezeigt wurde. Je dunkler das Blau, desto größer die Bedeutung für das Modell. Darüber hinaus erklärt ein kurzer Text oberhalb der Heatmap die Bedeutung der Hervorhebung. In einer neueren Studie von Ribeiro et al. (2016) hat ein Machine Learning Modell die Aufgabe, das Tier in einem Bild als Hund oder Wolf zu klassifizieren. Durch das Hervorheben bestimmter Bereiche des betrachteten Bildes als Heatmap, veranschaulicht das System, welche Bereiche bei der Klassifizierung am wichtigsten waren.

Die Algorithm Erklärungen liefern eine vereinfachte Erklärung des Algorithmus oder des Modells, welches dem System zugrunde liegt (Kulesza et al. 2013) (Nur ein Paper in dieser Analyse verwendete diese Methode. Kulesza et al. (2013) schufen verschiedene Ebenen von vereinfachten Erklärungen ihres Musikempfehlungsalgorithmus, um die Klangqualität ihrer Erklärungsschnittstelle zu manipulieren. Die detaillierteste Erklärung beschrieb den tatsächlichen Entscheidungsbaum, welches der Algorithmus des Systems verwendet hat. Die Erklärung mit mittleren Detaillierungsgrad beschrieb einen einfachen Entscheidungsbaum und die Erklärung mit einem niedrigen Detaillierungsgrad basierte auf einem Entscheidungsbaum mit nur einem Merkmal. Alle Erklärungen wurden zusammen mit der Empfehlung und in Textform gegeben.

# 2.4.2 Vignettenstudie zur Validierung der identifizierten Erklärungsmethoden und Messung des Einflusses auf die Akzeptanz

Aufbauend auf den Ergebnissen der Literaturrecherche wurden durch den projektbegleitenden Ausschuss ausgewählte Methoden mit einer experimentellen Vignettenstudie hinsichtlich ihres Potenzials zur Beeinflussung von Vertrauen und Akzeptanz getestet.

#### Methodik

Atzmüller und Steiner (2010) definieren eine Vignette als "eine kurze, sorgfältig konstruierte Beschreibung einer Person, eines Gegenstandes oder einer Situation, die

eine systematische Kombination von Merkmalen darstellt" (S. 128). Da die Experimentteilnehmer ihre "Überzeugungen, Einstellungen, Urteile, Kenntnisse oder ihr beabsichtigtes Verhalten" (S. 129) gegenüber verschiedenen konstruierten, aber realistischen Vignetten zum Ausdruck bringen, können Forscher diese abhängigen Variablen messen und gleichzeitig unabhängige Variablen durch die Wahl verschiedener Faktoren im Vignettendesign manipulieren und testen. Dies führt zu einer hohen internen und externen Validität (Atzmüller und Steiner 2010). In dieser Studie wurden die Vignetten dazu verwendet, die Teilnehmer so zu manipulieren, dass sie sich wie Entscheidungsträger verhalten, obwohl diese keine echte Entscheidungsträgerrolle innehatten, um dadurch die Generalisierbarkeit der Ergebnisse zu erhöhen. Darüber hinaus ermöglichte die Vignettenstudie die Untersuchung der zuvor gefundenen Erklärungsmethoden in einer fiktiven Arbeitssituation, in der BA in der Praxis eingesetzt werden kann.

Die Vignettenstudie wurde durchgeführt, um die Effekte einzelner Erklärungsmethoden auf die Akzeptanz zu untersuchen. Dies wurde umgesetzt, indem Unterschiede zwischen verschiedenen Gruppen gemessen wurden (es wurden entsprechend Gruppenvergleiche durchgeführt), wobei jede Gruppe eine ähnliche Vignette erhielt, die eine spezifische Situation und Aufgabe beschreibt. Der Faktor, der die Vignetten der Gruppen unterschied, war die zur Verfügung gestellte Erklärungsmethode. Das Experiment wurde auf Unipark durchgeführt, einem Online-Befragungstool, das von den Teilnehmern über einen URL-Link aufgerufen wurde und vollständig in deutscher Sprache zur Verfügung stand. In einem ersten Schritt wurden die Teilnehmer in die Situation eingeführt (siehe Abbildung 1). In dieser Situation mussten sich die Teilnehmer als Personalleiter eines Unternehmens hineinversetzen, der die Aufgabe hat, festzustellen, ob ein bestimmter Mitarbeiter beabsichtigt, das Unternehmen zu verlassen. Zur Unterstützung ihrer Entscheidungsfindung wurde den Teilnehmern ein BA-System zur Verfügung gestellt, das vorhersagt, ob ein Mitarbeiter das Unternehmen verlassen wird oder nicht. Das System basierte auf einem von Li (2017) entwickelten realen Modell des maschinellen Lernens, das verschiedene Mitarbeiterattribute wie die durchschnittliche monatliche Arbeitszeit, die im Unternehmen verbrachte Zeit oder die Frage, ob der Mitarbeiter in den letzten fünf Jahren befördert wurde, in ein Random Forest Modell einbezieht. Während die Teilnehmer darüber informiert wurden, dass das BA-System auf einem realen Modell basiert, erhielten sie keine weiteren Informationen über das zugrundeliegende Modell oder die Genauigkeit der Vorhersage.

Sie sind Human Resources Manager (HR-Manager) in einem großen Unternehmen. Ihre heutige Aufgabe ist es, zu entscheiden bei welchen Mitarbeitern das Risiko besteht, dass sie das Unternehmen verlassen.

Die Business-Intelligence & Analytics (BI&A) Abteilung Ihres Unternehmens hat Ihnen zur Unterstützung für diese Aufgabe ein **BI&A-System** zur Verfügung gestellt, welches anhand von verschiedenen Mitarbeiterattributen und mit Hilfe eines **Machine Learning Modells** vorhersagt, ob ein bestimmter Mitarbeiter das Unternehmen verlassen wird oder nicht.

Bitte versetzen Sie sich in diese Situation und die Rolle dieses HR-Managers. Betrachten Sie die Attribute [, die Erklärung]<sup>1</sup> und das Ergebnis ausführlich, bevor Sie Ihre eigene Vorhersage treffen. Im Anschluss werden Sie gebeten einen kurzen Fragebogen auszufüllen.

#### Info:

Der Einfachheit halber wird im gesamten Text die männliche Form verwendet; die weibliche und die neutrale Form sind selbstverständlich eingeschlossen. Bei dem hier verwendetem Machine Learning Modell handelt es sich um ein reales Modell basierend auf realistischen Daten. Weitere Informationen zu diesem Modell finden sie am Ende dieser Umfrage.

# Abbildung 18: Situationsbeschreibung der Vignette

Nachdem die Teilnehmer die Sachlage durchgelesen und ihr Verständnis der Situation bestätigt hatten, wurden den Teilnehmern alle Attribute eines fiktiven Mitarbeiters gezeigt. Zusätzlich erhielten sie Informationen über die bereitgestellten Attribute und die Prognose des Systems (siehe Abbildung 2 für ein Beispiel).

litarbeiterattribute:		Ergebnis des BI&A-Systems:
Attribut	Wert	Vorhersage des <u>BI&amp;A-Systems</u> für diesen N
Zufriedenheitslevel	73%	Wird das Unternehmen verlasser
Letzte Evaluation	vor 0,84 Jahren	
Anzahl an Projekten	5	Erklärung des BI&A-Systems:
Durchschnittliche monatliche Arbeitszeit	251 Stunden	Das System basiert sein Vorhersage-Modell au
Jahre im Unternehmen	6 Jahre	14.999 Mitarbeitern, mit jeweils 9 Attributen, 23,8% das Unternehmen verlassen haben.
Arbeitsunfall	Nein	Der Zufriedenheitswerts dieses Mitarbeiters lieg Durchschnitt von Mitarbeitern, die das Unterne
Beförderung in den letzten 5 Jahren	Nein	verlassen haben (0,66).
Abteilung	Vertrieb	Die Anzahl der Projekte dieses Mitarbeiters ist hi durchschnittliche Anzahl von Projekten von N
Gehalt	durchschnittlich	die das Unternehmen nicht verlassen haben (3,78).  Dieser Mitarbeiter ist länger im Unternehmen,
		durchschnittlicher Mitarbeiter, der das Unterne verlassen hat (3,38 Jahre).
ktribute [mögliche Werte]:  Zufriedenheitslevel: Wie zufrieden i [0%-100%]  Letzte Evaluation: Wann war die let		Dieser Mitarbeiter hat durchschnittlich mehr ge- ein durchschnittlicher Mitarbeiter, der das Ur nicht verlassen hat (199,06 Stunden).
Mitarbeiters? [0-1 Jahr] Anzahl an Projekten: An wie vielen momentan beteiligt? [2-7 Projekte] Durchschnittliche monatliche Arbei	Projekten ist der Mitarbeiter	Seit der letzten Evaluation dieses Mitarbeiters is vergangen als bei einem durchschnittlichen Mita das Unternehmen nicht verlassen hat (0,71 Jahre
der Mitarbeiter durchschnittlich in e Jahre im Unternehmen: Wie viele Ja im Unternehmen [2-10 Jahre]	inem Monat? [96-310 Stunden]	
Arbeitsunfall: Hatte der Mitarbeiter Arbeitsunfall? [Ja oder Nein]	in der Vergangenheit bereits einen	
Beförderung in letzten 5 Jahren: Ha Jahren eine Beförderung erhalten [		
Abteilung: Welcher Abteilung gehö Accounting, Service, Management,	rt der Mitarbeiter an? [Vertrieb,	

Abbildung 19: Beispiel für eine der genutzten Vignette

<sup>&</sup>lt;sup>1</sup> Dieser Teil war kein Bestandteil der Beschreibung für die Kontrollgruppe.

Diese Informationen waren für alle Gruppen gleich. Der Mitarbeiter, dessen Attribute angezeigt wurden, wurde vom Autor aus dem von Li (2017) verwendeten Trainingsdatensatz für das Maschine Learning Modell ausgewählt. Dieser Mitarbeiter hat das Unternehmen tatsächlich verlassen, was vom System korrekt vorhergesagt wird. Die Zusatzinformationen zu den Attributen enthielten eine Definition und ein möglicher Wertebereich für jedes der Attribute. Zusätzlich erhielt jede der Treatment Gruppen vom System eine andere Erklärungsmethode (siehe Tabelle 7). Alle Erklärungen wurden in Textform präsentiert und in natürlicher Sprache verfasst. Des Weiteren hatten die Erklärungen eine ähnliche Länge, um einen möglichen Einfluss durch die Präsentationsform oder die Länge der Erklärung zu minimieren. Die Teilnehmer wurden durch das Umfragesystem randomisiert einer von sechs Gruppen zugeordnet, bevor sie mit der Situation konfrontiert wurden. Das Erhebungsinstrument gewährleistete eine Normalverteilung der Gruppen und damit ähnliche Gruppengrößen. Nach der Überprüfung der gegebenen Informationen und der Vorhersage des Systems wurden die Teilnehmer gebeten, ihre eigene Vorhersage darüber abzugeben, ob dieser Mitarbeiter das Unternehmen verlassen wird oder nicht. Anschließend mussten die Teilnehmer fünf Fragen bezüglich ihres Vertrauens in das System und ihre Akzeptanz des Systems beantworten. Abschließend wurden die Teilnehmer gebeten, Kontrollfragen und Fragen zu ihrer Person zu beantworten.

Tabelle 7: Umsetzung der Erklärungsmethoden

Erklärungsmothodo	Erklärungstovt
Erklärungsmethode	Erklärungstext
Rule Trace	Das System basiert sein Vorhersage-Modell auf Daten von 14.999 Mitarbeitern, mit jeweils 9 Attributen, von denen 23,8% das Unternehmen verlassen haben.
	Der Zufriedenheitswert dieses Mitarbeiters liegt über dem Durchschnitt von Mitarbeitern, die das Unternehmen nicht verlassen haben (0,66).
	Die Anzahl der Projekte dieses Mitarbeiters ist höher, als die durchschnittliche Anzahl von Projekten von Mitarbeitern, die das Unternehmen nicht verlassen haben (3,78).
	Dieser Mitarbeiter ist länger im Unternehmen, als ein durchschnittlicher Mitarbeiter, der das Unternehmen nicht verlassen hat (3,38 Jahre).
	Dieser Mitarbeiter hat durchschnittlich mehr gearbeitet, als ein durchschnittlicher Mitarbeiter, der das Unternehmen nicht verlassen hat (199,06 Stunden).
	Seit der letzten Evaluation dieses Mitarbeiters ist mehr Zeit vergangen als bei einem durchschnittlichen Mitarbeiter, der das Unternehmen nicht verlassen hat (0,71 Jahre).

# Erklärungsmethode Der durchschnittlich ternehmen verlasse Unternehmen gebli Mitarbeiter, welche schnittlich an etwa Unternehmen nicht Mitarbeiter, welche Wahrscheinlichkeit noch nicht so lang i Mitarbeiter, welche nat durchschnittlich ben sind. Bei Mitarbeitern, welche schnittlich etwas mit Mitarbeitern, welche schnittlich etwas mit Mitarbeitern, welche mitarbeiter

# Der durchschnittliche Zufriedenheitswert von Mitarbeitern, welche das Unternehmen verlassen haben, war niedriger als von Mitarbeitern, welche im Unternehmen geblieben sind.

Mitarbeiter, welche das Unternehmen verlassen haben, waren durchschnittlich an etwas mehr Projekten beteiligt, als Mitarbeiter, welche das Unternehmen nicht verlassen haben.

Mitarbeiter, welche schon länger im Unternehmen sind, haben eine höhere Wahrscheinlichkeit das Unternehmen zu verlassen, als Mitarbeiter, welche noch nicht so lang im Unternehmen sind.

Mitarbeiter, welche das Unternehmen verlassen haben, arbeiteten im Monat durchschnittlich mehr als Mitarbeiter, welche im Unternehmen geblieben sind.

Bei Mitarbeitern, welche das Unternehmen verlassen haben, war durchschnittlich etwas mehr Zeit seit der letzten Evaluation vergangen als bei Mitarbeitern, welche im Unternehmen geblieben sind.

Sollte dieser Mitarbeiter das Unternehmen verlassen, fallen zusätzliche Kosten an, welche für die Neufindung und die Einarbeitung des Ersatzes aufgebracht werden müssen.

Außerdem würde die Produktivität in der Abteilung aufgrund von Unterbesetzung sinken und die Abteilungsziele könnten nicht erreicht werden.

#### Strategic

Das BI&A-System nutzt historische Daten des Unternehmens, um eine Vorhersage über eine mögliche Kündigung durch den Mitarbeiter zu treffen.

Das Ziel ist es zuverlässig vorherzusagen, ob der Mitarbeiter das Unternehmen verlassen wird. Das gibt dem Unternehmen die Möglichkeit, frühzeitig zu reagieren, einer möglichen Kündigung entgegenzuwirken und so die Mitarbeiterfluktuation zu verringern.

Dieser Mitarbeiter könnte zum Beispiel an einem Mitarbeiterbindungs-Programm teilnehmen und so von einem Verbleib überzeugt werden. Dies würde verhindern, dass zusätzliche Kosten entstehen welche z.B. für die Suche, Einstellung und Einarbeitung eines Ersatzes anfallen würden.

#### **Algorithm**

Das BI&A-System basiert seine Vorhersage auf einem Random-Forest Machine Learning Modell. Das Random-Forest Modell besteht aus einer Vielzahl von einzelnen Entscheidungsbäumen (in diesem Fall 10), die als Ensemble funktionieren.

Ein Entscheidungsbaum ist eine Flussdiagramm-ähnliche Baumstruktur, bei der jeder interne Knoten einen Test auf ein Attribut (z.B. Zufriedenheitslevel >0.5) abbildet. Desweiten stellt jeder Zweig ein Ergebnis des Tests dar (z.B. Wahr – Test trifft zu) und jeder Zweig endet in einem weiteren Test oder in einer Klassenvorhersage (Mitarbeiter verlässt das Unternehmen oder Mitarbeiter bleibt). Bei jedem Test wird der Datensatz in immer kleinere Teilmengen zerlegt.

Die Entscheidungsbäume werden vom System während des Trainings des Modells auf Basis von zufälligen Mitarbeitern und Attributen erstellt. Für das Training wurden 10.500 historische Datensätze von Mitarbeitern verwendet. Mit weiteren 4.499 Datensätzen wurde das Modell anschließend getestet.

Während der Klassifikation gibt jeder einzelne Baum im "Random Forest" eine Klassenvorhersage für den Mitarbeiter ab. Die Klasse mit den meisten Stimmen wird abschließen zu der Vorhersage dieses Modells benutzt.

Erklärungsmethode	Erklärungstext
Influence	Die folgenden Mitarbeiter-Attribute haben den größten prozentualen Einfluss auf das Ergebnis des Modells:
	Das Zufriedenheitslevel des Mitarbeiters beeinflusst das Ergebnis mit 30,33 Prozent am stärksten.
	Die Anzahl an Projekten, an denen der Mitarbeiter beteiligt ist, hat den zweitgrößten Einfluss mit 20,98 Prozent.
	Mit 17,42 Prozent hat die Anzahl an Jahren, die der Mitarbeiter bereits im Unternehmen arbeitet, den drittgrößten Einfluss auf das Ergebnis.
	Das Ergebnis wird von der durchschnittlichen monatlichen Arbeitszeit des Mitarbeiters zu 14,43 Prozent beeinflusst.
	Der Zeitpunkt der letzten Evaluation des Mitarbeiters beeinflusst 12,59 Prozent des Ergebnisses.
	Alle weiteren Attribute haben weniger als 2 Prozent Einfluss auf das Ergebnis.

Die Umfrage wurde sozialen Netzwerken für Berufstätige, z. B. auf LinkedIn und in verschiedenen Facebook-Gruppen für graduierte Studierende an mehreren deutschen Universitäten veröffentlicht. Dies führte zu 222 gültigen Antworten im Erhebungszeitraum, der vom 8. September bis zum 22. Dezember betrug. Von allen Teilnehmern waren 57,21 Prozent (N=127) männlich und 42,43 Prozent (N=94) weiblich und ein Teilnehmer identifizierte sich selbst als divers. Im Durchschnitt waren die Teilnehmer 30,76 Jahre alt, der jüngste war 21, der älteste 67 Jahre alt. Die meisten Teilnehmer hatten einen Bachelor-Abschluss (N=98) oder einen Master-Abschluss (N=87) und waren entweder angestellt (N=139) oder derzeit als Student eingeschrieben (N=67). Im Durchschnitt hatten die Teilnehmer 8,1 Jahre Berufserfahrung. Von allen angestellten Teilnehmern war ein großer Anteil reguläre Angestellte ohne Führungsverantwortung (N=106). Darüber hinaus identifizierten sich 16 als Manager, 11 als Abteilungsleiter, drei als Direktor und zwei als C-Level-Manager. Die am häufigsten vertretenen Abteilungen waren Vertrieb (N=35), Kundendienst (N=18) und Marketing (N=17), 12 Teilnehmer arbeiteten tatsächlich in einer Personalabteilung.

Die im Fokus stehende abhängige Variable ADH (adheres to the system's prediction) misst, ob sich der Benutzer an die Vorhersage des Systems hält. ADH ist eine Messgröße, die bereits mehrfach verwendet wurde um die Akzeptanz von Vorhersagen oder Empfehlungen in der Erklärungsliteratur zu beurteilen (Arnold et al. 2006; Önkal et al. 2008). ADH ist eine binäre Variable, wobei die Aussage "Dieser Mitarbeiter wird das Unternehmen nicht verlassen" mit 0 und die Aussage "Dieser Mitarbeiter wird das Unternehmen verlassen" mit 1 kodiert wurde. 1 gibt damit die Übereinstimmung mit der Vorhersage des Systems, welches anzeigte, dass der Mitarbeiter das Unternehmen verlassen wird, an. Da ADH damit eine binäre Variable darstellt, wurde um festzustellen, ob Erklärungen das Vertrauen und die Akzeptanz von BI&A erhöhen können, eine binäre logistische Regression durgeführt, um die Unterschiede zwischen den Treatmentgroup und der Kontrollgruppe hinsichtlich der angegebenen ADH-Werte zu testen.

#### **Ergebnisse**

Die Ergebnisse der logistischen Regression deuten darauf hin, dass es einen negativen Effekt zwischen der Bereitstellung von Erklärungen und der Akzeptanz der Vorhersage gibt, wobei die Effekte jedoch meist nicht signifikant auf einem allgemeingültigen Niveau (5%) sind. In anderen Worten, weisen die Ergebnisse darauf hin, dass die Probanden in der Kontrollkondition (ohne Erklärung) eher der Vorhersage des Systems akzeptiert und entsprechend die gleiche Einschätzung wie der Algorithmus abgegeben haben. Nur die Algorithm-Erklärungen zeigten einen 10%-signifikanten und negativen Einfluss auf ADH (Koeffizient = -.96, p = .056). Bei der Analyse der Mittelwerte der verschiedenen Gruppen zeigt die Kontrollgruppe ohne jegliche Erklärung die höchsten ADH-Werte (Mittelwert =.763, Standardabweichung = .431). Rule Trace ist die einzige Erklärungsmethode, die zu einer über 75-prozentigen Einhaltung führte, während die Strategic bzw. strategische Methode unter 70 Prozent und die Methoden Justification und Influence bei knapp unter 60 Prozent blieb. Die Bereitstellung der Algorithmus-Erklärung beläuft sich auf 21 Prozentpunkte weniger als die Kontrollgruppe und die niedrigste Einhaltung insgesamt (siehe Abbildung 3).

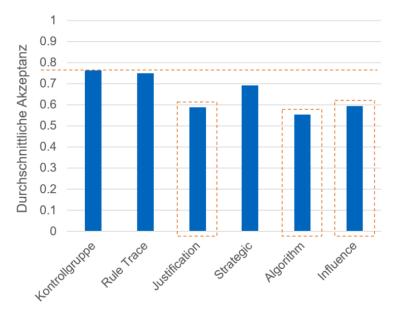


Abbildung 20: ADH (adheres to the system's prediction) für verschiedenen Erklärungen

Die Teilnehmer wurden auch gebeten, Erklärungsmethoden nach ihrer Verständlichkeit und Plausibilität zu bewerten (Skala 1 bis 5). Alle Erklärungsmethoden wurden hinsichtlich ihrer Verständlichkeit relativ hoch bewertet. Dabei lagen alle Mittelwerte über 3,6. Justification war die verständlichste Erklärungsmethode und die einzige Methode, die im Durchschnitt einen Wert über 4 erreichte (Mittelwert = 4,06, Standardabweichung = .814), während die Algorithmus-Erklärungen für die Teilnehmer am wenigsten verständlich waren (Mittelwert = 3,73, Standardabweichung = .838). Die Plausibilitätsbewertungen waren etwas niedriger, mit Mittelwerten über 3,3, aber unter 3,5. Hier führte die Influence Erklärung zu den höchsten Bewertungen (Mittelwert = 3,46, Standardabweichung = .803), vor der Justification Erklärung, die etwas weniger plausibel war (Mittelwert = 3,41, Standardabweichung = .892). Die Erklärungsmethode Influence führte zu den höchsten Bewertungen (Mittelwert = 3,46, Standardabweichung

= .803), vor der Justification Erklärung, die etwas weniger plausibel war (Mittelwert = 3,41, Standardabweichung = .892). Auch hier rangierte Algorithmus unter allen Erklärungsmethoden am niedrigsten (Mittelwert = 3,32, Standardabweichung = 1,07). Teilnehmer, die entweder Verständlichkeit oder Plausibilität niedrig bewerteten, wurden gebeten, eine schriftliche Begründung für die Bewertung abzugeben.

Einige Teilnehmer in der Rule-Trace Gruppe versäumten eine absolute Bewertung der Faktoren, z. B. ob sich diese positiv oder negativ auf das Ergebnis des Systems auswirkten, da "nicht ersichtlich war, wie die Daten ausgewertet wurden". Ein Teilnehmer wollte z. B. wissen, ob "[...] mehr Projekte als der durchschnittliche Mitarbeiter, der das Unternehmen verlassen hat, darauf hindeuten, dass er das Unternehmen früher verlassen würde?" Die Teilnehmer, die Zugang zur Justification Erklärung hatten, beklagten einige "komplizierte Syntaxen" und "Umschweifungen" in der Justification Erklärung und merkten an, dass "eine Grafik anstelle von oder als Unterstützung für die Erklärungen" hilfreich gewesen wäre. Ein Teilnehmer bemerkte weiter an, dass er oder sie nicht wisse, "welche der [dargestellten] Faktoren ... mit welchem Gewicht in die Bewertung [des Systems] einbezogen werden".

Einige Teilnehmer, die die strategischen Erklärungen erhalten hatten, kritisierten die "fehlende Erklärung, welche Variablen für die Vorhersage [des Systems] wichtig sind" und wiesen darauf hin, dass "es hilfreich wäre zu wissen, welcher Faktor/welche Faktoren besonders darauf hindeuten, dass der Mitarbeiter das Unternehmen bald verlassen wird". Zusätzliche Kommentare deuten darauf hin, dass die strategische Erklärung zu allgemein war und "spezifischer auf den Fall hätte zugeschnitten werden können". Ein Teilnehmer merkte an, dass "der Verweis auf die Methode, nach der das System funktioniert, keine ausreichende Rechtfertigung [für die Vorhersage des Systems] liefert", während andere lediglich feststellten, dass es keinen "Grund gebe, warum der Mitarbeiter kündigen sollte".

Die Teilnehmer in der Algorithm-Gruppe wiesen am stärksten auf die fehlende Erklärung hin, wie "die einzelnen Attribute die Entscheidung" des Systems "beeinflussten". Ein Teilnehmer gab an, dass er oder sie "eine Bezugnahme auf die Attribute erwartet hätte, d.h. es ist nicht klar, ob die Beförderungen im Zusammenhang mit der Dauer der Betriebszugehörigkeit berücksichtigt wurden". Während ein Teilnehmer berichtete, dass "die Erklärung der Funktionsweise des Systems sehr plausibel war", schrieben andere, dass sie nicht in der Lage seien, "Begriffe wie Klassen und Beschreibungen wie die Aufteilung des Datensatzes in Teilmengen" zu verstehen. Insbesondere ein Teilnehmer gab an, dass die Erklärung des Algorithmus "zu technisch" sei. Seiner Meinung nach sei es "irrelevant für die Entscheidungsfindung", bestimmte Begriffe eines Entscheidungsbaums zu kennen, und das Lesen dieser Erklärung werde das Misstrauen verstärken. Daher, so schlussfolgerte er oder sie, "sollte sich die KI menschenähnlicher ausdrücken".

Während die Erklärungsmethode Influence den Teilnehmern Informationen darüber lieferten, welche Attribute die Entscheidung des Systems am meisten beeinflussten,

verlangten die Teilnehmer dennoch Informationen darüber, ob diese Attribute einen positiven oder negativen Einfluss auf die Entscheidung hatten. Ein Teilnehmer antwortete, dass "es keinen ersichtlichen Grund gibt, warum die einzelnen Faktoren eine Entscheidung zum Verlassen des Unternehmens unterstützen und die Argumentation damit nicht nachvollziehbar ist. Es wären mehr Argumente oder Erklärungen zu den Verbindungen zwischen den Faktoren erforderlich". Mehrere Teilnehmer erklärten, dass sie die Attribute in ihrer Gewichtung unterschiedlich bewerten würden, z. B. aufgrund "persönlicher Erfahrungen und Prioritäten". Da das Beförderungsattribut relativ gering gewichtet wurde, kommt einer von ihnen sogar zu dem abschließenden Urteil, dass "das System (potenziell) irreführend ist".

Unabhängig von der zugeordneten Erklärung nannten Teilnehmer das Fehlen "weicher" oder "unpersönlicher Faktoren", um eine richtige Entscheidung zu treffen. Ihrer Meinung nach haben andere Faktoren "wie z.B. Führungsstil, ..., persönliche Entwicklungsziele und vieles mehr" einen Einfluss darauf, ob ein Mitarbeiter ein Unternehmen verlässt.

Zusammenfassend lässt sich feststellen, dass keine klaren positiven Effekte zwischen den einzelnen Erklärungsmethoden und der Akzeptanz des Systems vorliegt ist. Mögliche Ursachen dafür, werden im nachfolgenden Abschnitt diskutiert.

2.4.3 Gegenüberstellung der Ergebnisse: Bias-Vermeidungsmethoden im Kontext von Business Analytics (inkl. Interviews)

#### Ergebnisdiskussion mit Psychologen

Die Ergebnisse der Vignettenstudie geben keine Hinweise darauf, dass Erklärungen die Akzeptanz von Business Analytics erhöhen. Im Gegenteil, die Ergebnisse deuten darauf hin, dass die Bereitstellung von Erklärungen die Akzeptanz sogar reduziert. Dies steht im Widerspruch zu den Ergebnissen von Arnold et al. (2006). Eine mögliche Erklärung wird von Logg et al. (2019) gegeben, die über eine hohe Akzeptanz von Ergebnissen eines Algorithmus berichtet. Ähnlich wie in der Studie von Logg et al. (2019) haben die Teilnehmer in der vorliegenden Studie keine Möglichkeit gehabt, die Leistung des BA-Systems zu erleben und konnten daher keine fehlerhaften Vorhersagen des Systems beobachten. Dies kann bei Teilnehmern auch zu einem übersteigerten Vertrauen in das BA-System führen (vgl. Automation Bias). Während die Probanden die Ergebnisse des Systems ohne Erklärungen hinzu zunehmen scheinen, löst die zugegebene Erklärung ein Hinterfragen der Ergebnisse aus und reduziert somit ein mögliches übersteigertes Vertrauen in das BA-System.

Durch die Bereitstellung von Erklärungen wurden die Teilnehmer in die Lage versetzt einen tieferen Einblick in die Funktionsweise des BA Systems zu erhalten. Dietvorst et al. (2015) beschreiben einen Effekt, der auftritt, wenn Teilnehmer beobachten wie ein System fehlerbehaftet ist und zu einer Reduktion der Akzeptanz in die Ergebnisse des Algorithmus führt, auch wenn dieses ein höheres Leistungsvermögen aufweist. Ein

ähnlicher Zusammenhang ist bei der vorliegenden Vignettenstudie auch denkbar. Teilnehmer können durch die zusätzlichen Informationen der Erklärungen eher den Eindruck gewinnen, dass das BA-System potenziell fehlerbehaftet ist, als Teilnehmer in der Kontrollgruppe. Einige Teilnehmer merken beispielsweise im Abschlussfragebogen an, dass sie nicht mit der Auswahl der Attribute einverstanden sind, die das System für seine Entscheidung nutzt. Die Verminderung der Akzeptanz der Ergebnisse des BA-Systems kann zudem an Bias liegen, die durch die Erklärungsmethoden gefördert werden. Beispielsweise kann eine Erklärung, die aus Sicht des Teilnehmers unvollständig oder nicht optimal ist, zu dem Schluss führen, dass die eigene Bewertung zu einem besseren Ergebnis führt. Ist dies eine Fehleinschätzung, liegt ein Fall von Overconfidence Bias vor.

Zusammengefasst deuten die Ergebnisse der Vignettenstudie darauf hin, dass die Verwendung von Erklärungsmethoden sowohl Bias vermindern, als auch fördern kann. Die Diskussion der Ergebnisse und Erklärungsansätze für die ermittelten Ergebnisse wurden im Gespräch mit Psychologen als möglich erachten. Um eine definite Aussage zutreffen, wurde übereinstimmend die Aussage getroffen, dass weitere empirische Untersuchungen notwendig sind um einzelne Zusammenhänge zu beweisen als auch um die vorliegende Vignettenstudie zu replizieren. Es wurde in den Gesprächen klar, dass Erklärungen und generell Kontextinformationen so gewählt werden sollten um, das richtige Maß an Vertrauen zu generieren und die kognitiven Verzerrungen soweit wie möglich zu reduzieren. Dieses Maß an Vertrauen beschreiben Lee und See (2004) in einer vielzitierten Veröffentlichung als kalibriertes Vertrauen (vgl. Abbildung 21).

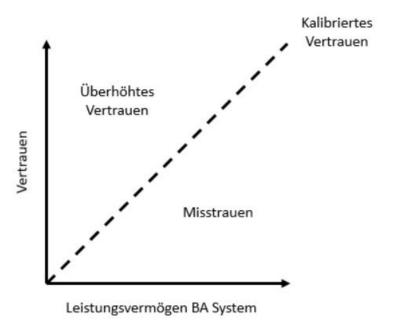


Abbildung 21: Kalibriertes Vertrauen (in Anlehnung an Lee und See 2004)

Um im Kontext eines BA Systems ein angemessenes Maß an Vertrauen zu erreichen, empfiehlt sich folglich eine Kombination verschiedener Erklärungsmethoden und Kontextinformationen, die im Anwender weder ein überhöhtes Vertrauen noch ein Misstrauen hervorrufen. Während bereits Erklärungsmethoden für Algorithmen vorgestellt

wurden, die das kritische Auseinandersetzen mit dem Algorithmus fördern und tendenziell das Vertrauen reduzieren, wurde im Rahmen der Gespräche mit Psychologen auf erklärungsähnliche Methoden zur Bias Reduktion aufmerksam gemacht, die im Rahmen folgenden Abschnitt vorgestellt werden.

Ausgehend von zwei umfangreichen Literaturreviews (Soll et al., 2015; Kaufmann et al., 2009) wurden Bias-Vermeidungsmethoden aufgearbeitet, die im Kontext von Business Analytics Verwendung finden können. Diese lassen sich gruppieren in übergeordnete Vermeidungsmethoden, die in jeglichen Entscheidungssituationen bzw. in spezifischen Entscheidungssituationen greifen und zudem in technische Vermeidungsmethoden. Letztere beziehen sich vorwiegend auf die Anpassungen von Darstellungen und Analysen zur Vermeidung von kognitiven Verzerrungen. Zudem wurden Beispiele aus der Praxis in einem Workshop erfasst und auf die jeweiligen Vermeidungsmethoden zugeordnet.

## Übergeordnete Vermeidungsmethoden

**Schulungen** (Soll et al. 2013). Eine Möglichkeit kognitiven Verzerrungen zu begegnen ist es, Entscheidungsträgern in allgemeinen Regeln und Prinzipien der Entscheidungsfindung zu schulen. So zeigen Studien beispielsweise, dass Studierende, die eine Lehrveranstaltung in Wirtschaftswissenschaften oder Statistik absolviert haben und damit grundlegende Prinzipien aus diesen Disziplinen erlernt haben, eher in der Lage sind kognitive Verzerrungen zu vermeiden (Larrick 2004). Als weiteres Beispiel, zeigen (Peters et al. 2006), dass ein enger Zusammenhang zwischen geringen mathematischen Fähigkeiten und der Anfälligkeit für bestimmte Entscheidungsfehler, wie z.B. Framing und vielen anderen Verzerrungen besteht.

#### Beispiele aus der Business Analytics Praxis

Entscheidungsträger können beispielsweise in Wahrscheinlichkeitstheorie geschult werden (z. B. über Online-Kurse) um das Eintreten von Ereignissen auf Basis von Analysen und Reports besser einordnen zu können.

Allgemeines Bewusstsein für kognitive Verzerrungen (Soll et al. 2013). Das Schaffen eines allgemeinen Bewusstseins für kognitive Verzerrungen bei Entscheidungen unter Entscheidungsträgern kann als übergeordnete Bias-Vermeidungsstrategie verstanden werden. So zeigen beispielsweise (Babcock und Loewenstein 1997), dass alleine die Aufklärung über die Existenz einer bestimmten kognitiven Verzerrung, die Qualität von Entscheidungen verbessern kann. Möglichkeiten zum Schaffen eines Bewusstseins umfassen beispielsweise das Bereitstellten von Lesematerialen oder spezifische Trainings, die die Funktionsweise kognitiver Verzerrungen vermitteln. Diesen Zweck verfolgt auch der im vorherigen Kapitel vorgestellte Bias-Katalog.

#### Beispiele aus der Business Analytics Praxis

Entscheidungsträger lesen sich in den im Katalog zur Reduktion von Bias, der im Forschungsprojekt erarbeitet wurde im Selbststudium ein. Die erarbeiteten Erkenntnisse können anschließend in einem Teamworkshop gemeinsam besprochen und auf den unternehmensspezifischen Kontext bezogen werden.

#### Entscheidungssituationsspezifische Vermeidungsmethoden

Blickwinkel wechseln (Soll et al. 2013). Im Rahmen dieses Vermeidungsansatzes ist der Entscheidungsträger angehalten den eigenen Blickwinkel auf die Entscheidungssituation und Entscheidungsgrundlage zu wechseln. In anderen Worten, soll der Blickwinkel die Situation aus Sicht einer anderen an der Entscheidungsfindung beteiligten Partei einnehmen. So zeigen (Faro und Rottenstreich 2006) beispielsweise, dass allein das Erstellen von Prognosen darüber was andere tun werden, Fehlprognosen in Bezug der eigenen Strategie vermindert. Blickwinkel wechseln ist nicht in allen Entscheidungssituationen anwendbar, sondern erfordert beispielsweise das Vorhandensein von Verhandlungspartnern oder Konkurrenten. Eine Umsetzungsmöglichkeit stellt z. B. das gemeinsame Brainstormen in einem Teammeeting dar.

#### Beispiele aus der Business Analytics Praxis

Bei der Abstimmung und strategischen Planung auf Basis von Marktprognosen werden gemeinsam die möglichen strategischen Entscheidungen der Konkurrenz hergeleitet.

Alternativen (Kaufmann et al. 2010). Neben der verzerrungsfreien Auswahl aus Entscheidungsalternativen ist ebenso wichtig, über eine ausreichende Anzahl von Entscheidungsalternativen im ersten Schritt zu verfügen. Hier kann auch bereits der Hinweis auf bestehende Entscheidungsalternativen relevant sein. So zeigen beispielsweise (Kahneman und Frederick 2005), dass Menschen weniger ausgeben, wenn sie nur daran erinnert werden, dass sie ihr Geld für andere Käufe aufsparen können. Alternativen generieren und aufzeigen ist keine allgemeine Vermeidungsmethode, sondern muss auf die jeweilige Entscheidungssituation zugeschnitten werden.

#### Beispiele aus der Business Analytics Praxis

Bei der Durchsprache von Analysen in einem Teammeeting werden alle Teilnehmer gebeten, die sich aus ihrer Sicht ergebenden Entscheidungsalternativen kurz zu benennen. Erst auf dieser Basis wird eine Entscheidung getroffen.

**Devil's Advocat** (Kaufmann et al. 2010). Für diese Vermeidungsmethode muss eine weitere Partei hinzugezogen werden, die die Entscheidung des Entscheidungsträgers in Frage stellt und gegen die Position des Entscheidungsträgers argumentiert. Das Ziel hierbei ist es Unzulänglichkeiten in der Position des Entscheidungsträgers zu erkennen und Verzerrungen aufzudecken (Herbert und Estes 1977). Es wurde beispielsweise gezeigt, dass der Einsatz eines Devil's Advocate in der frühen Phase der Ent-

scheidungsfindung, eine verzerrte Informationssuche (z. B. Confirmation Bias) reduzieren oder sogar verhindern kann (Schulz-Hardt et al. 2002). Dieser Vermeidungsansatz muss auf die spezifische Entscheidung zugeschnitten werden.

#### Beispiele aus der Business Analytics Praxis

Entscheidungsträger müssen ihre Entscheidungen auf Basis von Analysen und Reports immer im Rahmen eines kurzen Vortrags vor einem weiteren Mitarbeiter präsentieren. Dieser Mitarbeiter wird angehalten ausschließlich kritische Fragen zu stellen.

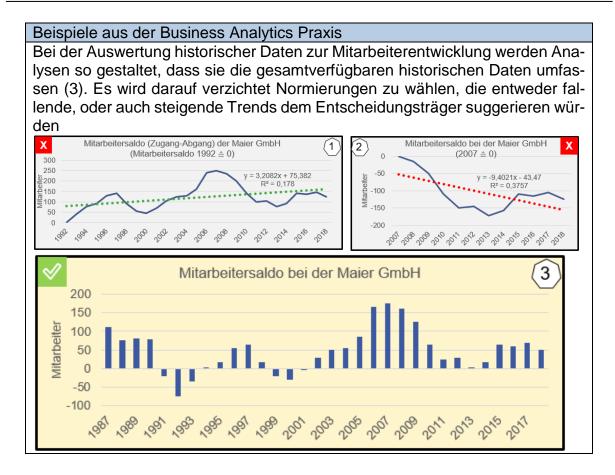
Weisheit der Massen (Soll et al. 2013). Diese Vermeidungsmethode umfasst, dass Entscheidungen nicht von einzelnen Entscheidungsträgern getroffen werden, sondern von einer Gruppe von Entscheidungsträgern. Die Meinungen der Entscheidungsträger werden gewichtet bzw. einem Votum unterzogen. Es hat sich gezeigt, dass Entscheidungen zu kombinieren (z.B. durch Durchschnitts- oder Mehrheitsregeln) ein effektives Mittel ist um Entscheidungen zu verbessern (R. Clemen und K. C. Lichtendahl 2002).

#### Beispiele aus der Business Analytics Praxis

Entscheidungen auf Basis von Analysen und Reports werden in Gruppenvotums getroffen. Ein Mitarbeiter bereitet hierfür eine Entscheidungsgrundlage im Vorhinein auf.

#### **Technische Vermeidungsmethoden**

Skalen (Soll et al. 2013). Skalen können so angepasst werden, dass sie das Aufkommen von kognitiven Verzerrungen vermindern. Auf der einen Seite sollten Skalen so transformiert werden, dass der Entscheidungsträger einen linearen Zusammenhang mit dem Entscheidungsziel aus der Skala herauslesen kann. Nach einem Beispiel von (Larrick und Soll 2008), wird z.B. die Veränderung von MPG (miles per gallon) von 10 auf 11 deutlich geringer wahrgenommen, als eine Veränderung von 33 auf 50. Dabei bedeuten beide eine Veränderung von 1 Gallone pro 100 Meilen und die Skala könnte daher beispielsweise eine Entscheidung für ein Fahrzeug verzerren (z.B., "Fahrzeug mit kleinerem Kraftstoffverbrauchs"). Auf der anderen Seite sollen Skalen so genormt werden, dass Attribute einer Entscheidungsgrundlage eine sinnvolle Gewichtung erhalten. So beschreiben beispielsweise (Camilleri und Larrick 2014), dass Treibstoffkosten eines Fahrzeugs höher gewichtet werden, wenn sie (sinnvollerweise) entsprechend der Lebenszeit des Fahrzeugs genormt werden (z.B. \$17.500 pro 100.000 Meilen statt eines kleineren Nenners).

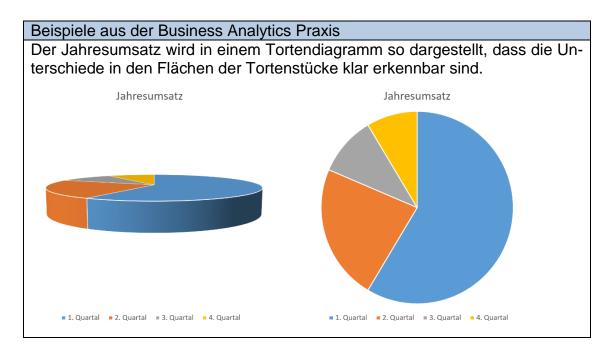


**Beschreibungen** (Soll et al. 2013). Beschreibungen können so angepasst werden, dass sie das Aufkommen von kognitiven Verzerrungen vermindern. Im spezifischen sollen Beschreibungen so gestaltet werden, dass sie nicht ausgewählte Entscheidungsalternativen betonen, sondern gleichwertig betrachten. So fördert das Framing von Entscheidungsalternativen nach Gewinnen und Verlusten (siehe vorheriges Kapitel) beispielsweise das Aufkommen von kognitiven Verzerrungen (Kahneman und Frederick 2005).

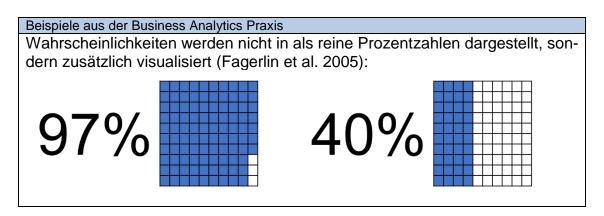
#### Beispiele aus der Business Analytics Praxis

Im wöchentlichen Report zur Overall Equipment Effectiveness (OEE) mehrerer Produktionslinien wird jede Produktionslinie mit der exakt gleichen Wortwahl beschrieben. Hierfür wird im Vorhinein eine neutrale Vorlage erstellt. Abweichungen finden sich nur in den in der Beschreibung verwendeten Zahlen.

**Darstellungen** (Soll et al. 2013). Darstellungen können so angepasst werden, dass sie das Aufkommen von kognitiven Verzerrungen vermindern. Beispielsweise nutzte das Landwirtschaftsministerium der Vereinigten Staaten in der Vergangenheit eine Lebensmittelpyramide als visuellen Leitfaden, der anzeigt, wie viel ein typischer Amerikaner aus verschiedenen Nahrungsmittelgruppen (z. B. Obst, Gemüse, Getreide usw.) essen sollte. Dieser Leitfaden war zu abstrakt (Heath and Heath, 2010). Daher zeigt eine neue Darstellung nun das Bild eines Tellers, der Lebensmittel in der Proportion der verschiedenen Nahrungsmittelgruppen visualisiert.



**Wahrscheinlichkeiten** (Soll et al. 2013). Wahrscheinlichkeiten können so dargestellt werden, dass sie das Aufkommen von kognitiven Verzerrungen vermindern. Probabilistische Informationen sind häufig verwirrend und sollten so dargestellt werden, dass sie für den Entscheidungsträger verständlich sind. Als Beispiel kann die Angabe relativer Häufigkeitsinformationen (z. B. 1 von 10.000 statt 0,01%) helfen (Hoffrage et al. 2000).



#### 2.4.4 Fazit zu Arbeitspaket 4

In Arbeitspaket 4 wurden im Rahmen einer systematischen Literaturrecherche geeignete Erklärungsmethoden ermittelt, die einen Effekt auf die Akzeptanz von Business Analytics haben. Die Auswirkung einer Auswahl von Erklärungsmethoden wurde mittels einer Vignettenstudie analysiert. Die Ergebnisse dieser Studie ergaben, dass Erklärungen bewusst eingesetzt werden müssen um nicht die gewünschte Wirkung zu verfehlen. Die Ergebnisse der Studie wurden anschließend mit Psychologen insbesondere im Kontext möglicher Bias diskutiert. Abschließend werden Methoden aufgeführt, die mögliche Bias im Kontext von Business Analytics reduzieren können.

#### 2.5 Arbeitspaket 5

Das Arbeitspaket 5 "Trainingskonzept und Demonstrator" dient der Entwicklung eines IT-Demonstrators sowie Schulungsmaßnahmen zur Steigerung der Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse sowie zur Reduktion von Biases.

Durchgeführte Arbeiten	Erzielte Ergebnisse
Überführung und <b>Publikation eines Pra- xisleitfadens</b> auf Basis der im For- schungsvorhaben gewonnenen Erkennt- nisse.	Die in den vorangegangenen Arbeitspaketen gewonnenen Erkenntnisse wurden in einen Praxisleitfaden "Steigerung der Akzeptanz von Business Analytics durch Erklärungen und Reduktion von Biases" überführt, welcher unter anderem Erkenntnisse zur Steigerung der Akzeptanz mittels Erklärungen umfasst. Zudem wurde eine "Anleitung zur Steigerung der Akzeptanz mittels transparenter Erklärungen" publiziert.
Modifikation mehrerer etablierter Business Analytics Algorithmen (IT-Demonstrator) zur Verbesserung ihrer Erklärbarkeit und damit zur Steigerung ihrer Akzeptanz.	Drei Business Analytics Algorithmen (Lineare Regression, Logistische Regression, Entscheidungsbäume) wurden zur Verbesserung ihrer Erklärbarkeit in der Programmiersprache Python modifiziert. Der IT-Demonstrator zur verbesserten Erklärbarkeit von Business Analytics Algorithmen wurde frei zugänglich publiziert.
Validierung des Demonstrators im Rahmen von Fallstudien mit Unternehmen und Überführung der gewonnenen Erkenntnisse in den Praxisleitfaden.	Der Demonstrator und der Praxisleit- faden wurden im Rahmen von Fallstu- dien mit Unternehmen validiert. Die Ergebnisse wurden in den Praxisleitfa- den übernommen.

# 2.5.1 Publikation eines Praxisleitfadens und einer Anleitung als Schulungsmaßnahmen für kmU

Die Projektergebnisse der Arbeitspakete 1 bis 4 wurden zu einem Praxisleitfaden aufbereitet, der im Rahmen der Reihe "IPRI-Praxis" (ISSN 2196-3339) mit dem Titel "Steigerung der Akzeptanz von Business Analytics durch Erklärungen und Reduktion von Biases" veröffentlicht wurde. Das IPRI-Praxispaper fokussiert die beiden großen Themenbereiche dieses Forschungsprojekts, und zwar die Maßnahmen zur Steigerung der Akzeptanz sowie Bias-reduzierende Maßnahmen.

Zusätzlich zu diesem IPRI-Praxispaper wurde eine "Anleitung zur Steigerung der Akzeptanz mittels transparenter Erklärungen" publiziert, die frei zum Download verfügbar ist. Die Anleitung fokussiert die Wirkungsweise von Erklärungsmethoden zur Steige-

rung der Akzeptanz BA-Systemen und datenbasierten Erkenntnissen. Praktiker können diese Anleitung nutzen, um die Akzeptanz der Nutzer solcher Analysen im eigenen Unternehmen zu steigern. Folgende Erklärungsansätze werden dabei betrachtet: Justification, Rule Trace, Strategic, Influence sowie Algorithm.

#### 2.5.2 Modifikation mehrerer etablierter Business Analytics Algorithmen (IT-Demonstrator)

Viele Anwendungen für maschinelles Lernen (ML) in verschiedenen Szenarien erfordern eine Erklärung. Bestehende Ansätze werden jedoch in der Regel nicht an nichttechnische Interessengruppen gerichtet, die der Erklärung jedoch bedürfen. Wenn man die praktische Relevanz von ML-Techniken weiter betrachtet, werden lineare und logistische Regressionsmodelle bei weitem immer noch am häufigsten verwendet. Die Kombination verbaler Erklärungen mit Erkenntnissen aus der Human Computer Interaction (HCI) und den Sozialwissenschaften bietet einen vielversprechenden Ansatz für die Erstellung von Erklärungen, die besonders für nichttechnische Benutzer geeignet sind. Um die Lücke zwischen diesen konzeptionellen Einsichten und den tatsächlichen Erklärungen zu schließen, bietet das etablierte Feld der Toolkit-Forschung einen vielversprechenden Weg. In diesem Zusammenhang wird im folgenden Kapitel beantwortet, wie Fortschritte bei der Generierung von Erklärungen aus erklärbarer künstlicher Intelligenz (Explainable Artificial Intellicence = XAI), HCI und Sozialwissenschaften in einem anwendungsfallunabhängigen Toolkit vereinheitlicht werden können, um Erklärungen zu generieren, die das nichttechnische Benutzerverständnis für lineare und logistische Modelle verbessern.

#### Methodik

Um diese komplexe Frage zu beantworten, wurde ein zweistufiger Prozess durchgeführt. Zunächst wurde eine Literaturrecherche durchgeführt, um relevante konzeptionelle Kriterien für das Erklärungsdesign für nichttechnische Benutzer zu sammeln. Da es bereits viele Literaturerhebungen in den umrissenen Bereichen XAI, HCI und Sozialwissenschaften gibt, wurde keine neue systematische Erhebung durchgeführt, sondern bestehende als zentrale Bezugspunkte herangezogen. Außerdem wurden konzeptionelle Beiträge in der Toolkit-Forschung auf relevante Aspekte eines erfolgreichen Toolkit-Designs überprüft. Ähnlich wie beim obigen Ansatz wurden Literaturrecherchen, die bereits Erkenntnisse zu diesem Thema zusammenfassen, als Hauptreferenzquelle herangezogen. Die resultierenden Ergebnisse wurden dann durch Kriterien aus zusätzlichen Referenzen ergänzt, die im Rahmen der verwendeten Literaturrecherchen identifiziert wurden. Während der gesamten Suche lag der Schwerpunkt auf konzeptionellen Arbeiten und zielte darauf ab, die kritischsten Faktoren zu ermitteln, um einen angemessenen Umfang beizubehalten. In diesem Zusammenhang wurden Literaturkriterien zur Generierung von Erklärungen aufgenommen, wenn sie für das jeweilige Publikum, ein anwendungsfallunabhängiges Toolkit-Design und den bereitgestellten Modellkontext geeignet waren.

In einem zweiten Schritt wurde anschließend ein konzeptioneller Rahmen abgeleitet, der alle Ergebnisse zusammenfasst und deren Zusammenspiel darstellt. Aufbauend auf der resultierenden Übersicht wurde schließlich eine konkrete Toolkit-Architektur entwickelt, die die gesammelten Kriterien mit konkreter Software und UI-Implementierung verknüpft.

Informationskategorie	Informationsgehalt
Eingabedaten	Eingabedatenart
	Quellinformationen der Eingabedaten
	Infos zur Datenproduktion und Etiketten
	Informationen zu Stichprobengröße und Trainingsdaten
	Einschränkungen und Verzerrungen der Eingabedaten
Systemausgabe	Art der Systemausgabe
	Bedeutung der Systemausgabe
	Umfang der Systemfähigkeit
	Verwendung der Ausgabe über Systeme hinweg
Systemleistung	Systemgenauigkeit
Wie (global) Logik von Sys-	Verwendete Vorhersagefunktionen
temvorhersagen	Gesamtsystemlogik (Auswirkungen einzelner Features und verwen-
	dete Regeln)
	Verwendeter Algorithmus (einschließlich eingestellter Parameter)
Sonstige	Erläuterungen zur ML-bezogenen Terminologie
	Gründe für die Verwendung einer bestimmten Eingabevariablen
	Erklärungen zur ML-Terminologie

#### **Toolkit-Anforderungen**

Die vorherrschende Literatur stellt wichtige Faktoren dar, die für das Generieren von Erklärungen und das Entwerfen entsprechender Benutzeroberflächen (UI) relevant sind, um diese anzuzeigen. Es fehlen jedoch noch die Kriterien für das Toolkit, das ein Software-Framework für Erklärungen bilden soll. In diesem Zusammenhang wurden in der bisherigen Literatur wesentliche Eigenschaften festgelegt, um ein effektives Tool-kit-Design zu gewährleisten und letztendlich die Vorteile dieses Konzepts zu nutzen. Erstens basiert die allgemeine Struktur von Toolkits normalerweise auf einzelnen Komponenten und ist durch eine Modularisierung der bereitgestellten Funktionen gekennzeichnet, während die Gesamtfunktionalität des Toolkits für Endbenutzer integriert bleibt (Myers et al., 2000). Bei der Übertragung auf Erklärungssysteme haben frühere Forscher bereits eine Trennung zwischen einem Modell und einer Erklärungs-UI-Komponente konzipiert. Benutzer interagieren über die Benutzeroberfläche mit Erklärungen, während das zugrunde liegende Modell sie bereitstellt und ihre Grenzen festlegt. Daher bildet dieses Konzept die Grundlage für jedes Systemdesign, auf dem zusätzliche Funktionen modularisiert werden können (Gunning & Aha, 2019).

Unter Berücksichtigung dieser strukturellen Eigenschaft müssen mehrere andere Ziele für ein effektives Systemdesign sichergestellt werden. In diesem Zusammenhang zielen Toolkits darauf ab, die Bauzeit und Komplexität für Systemersteller zu reduzieren, indem Konzepte gekapselt und in entworfenen Toolkit-Teilen zugänglich gemacht werden. Anschließend müssen geeignete Komponenten eine von außen zugängliche, gebündelte Funktionalität sicherstellen (Greenberg, 2007). Dabei sollten die resultierenden Elemente vorhandenes Wissen und Know-how aus dem Bereich einbeziehen, für den das Toolkit erstellt wurde (Greenberg, 2007). Auf diese Weise sollten Systemersteller dazu gebracht werden, korrekte Lösungen unter Verwendung des im Toolkit vorcodierten Wissens zu erstellen (Myers et al., 2000).

#### Konzeptioneller Rahmen für Literaturkriterien

Die beschriebenen Kriterien sind nun in einer Rahmendarstellung strukturiert, um ihr Zusammenspiel vor einer technischen Realisierung darzustellen. Eine solche Abstraktion ist unerlässlich, da sie ein strukturierteres Design ermöglicht und Flexibilität und Erweiterbarkeit sicherstellt.

Als allgemeine Struktur sind alle Literaturkriterien in einer Softwaredimension, einer Erklärungsdimension und einer algorithmischen Dimension organisiert. Die Softwaredimension umfasst alle Ziele im Zusammenhang mit der Softwareimplementierung des Toolkits, unabhängig von einem bestimmten Algorithmus. Hierin werden die beschriebenen Toolkit-Kriterien aufgenommen. Die algorithmische Dimension enthält den Satz von ML-Algorithmen, für die Erklärungen generiert werden. Hierbei werden lineare und logistische Regressionen wie zuvor begründet erfasst. Alles, was mit der Generierung von Erklärungen für diese Modelle zusammenhängt, wird dann durch die Erklärungsdimension zusammengefasst. Letzteres wird logischerweise von der algorithmischen Dimension beeinflusst, da Modelle grundlegend bestimmen, welche Erklärung verfügbar sein könnte.

Um die Vielfalt der identifizierten Erkenntnisse zum Erklärungsdesign zu erkennen, wird die entsprechende Dimension weiter unterteilt. Hier wurden eine erklärungstechnische Perspektive, eine funktionale Perspektive (funktionale Ziele), eine menschliche Perspektive (Sozialwissenschaften) und eine Designperspektive (HCI) gebildet. Diese entsprechen den Erkenntnissen, die aus den jeweiligen Bereichen der Literatur gewonnen wurden. Dabei berücksichtigt die Perspektive der Erklärungstechnik alle Posthoc-Ansätze, um Erklärungen abzuleiten. Da hier nur algorithmisch transparente Modelle berücksichtigt werden, wird diese Perspektive nicht weiter detailliert beschrieben, da keine komplizierte Ableitung der Erklärung erforderlich ist.

#### **Allgemeine Toolkit-Implementierung**

In einem ersten Schritt werden allgemeine Entwurfsoptionen für das gesamte Toolkit beschrieben. Für die Gesamtimplementierung wurde eine Serveranwendung mit einer webbasierten Benutzeroberfläche erstellt, die auf mehreren Programmiersprachen basiert. Python wird für alle Backend-Prozesse wie Datenverarbeitung oder Modellbildung verwendet, während HTML, CSS und JavaScript ein vollständig webbasiertes Frontend implementieren. Um die Webanwendung zu realisieren und ein reibungsloses Zusammenspiel zwischen den verschiedenen Programmiersprachen zu gewährleisten, wird das Open-Source-Python-Webentwicklungsframework Django verwendet. Es ermöglicht die schnelle Entwicklung skalierbarer Webanwendungen, indem die Arbeitsbelastung in Bezug auf Webserververwaltungsthemen wie Anforderungsbearbeitungs- oder Sicherheitsthemen (Django, 2021). Dies ermöglicht eine stabile Anwendungsumgebung, während der Fokus auf der Generierung von Erklärungen liegt.

Erstens wird durch die Verwendung dieser bekannten Technologien die einfache Lernbarkeit des Toolkits sichergestellt. Die Programmiersprachen gelten als Standard für ihre jeweiligen Zwecke und sind weit verbreitet. Viele standardisierte Pakete stehen für ML-relevante Operationen und das UI-Design zur Verfügung (Kaggle, 2020; Stack-Overflow, 2020). Darüber hinaus reduziert Django die Komplexität bei der Bereitstellung und Wartung einer Webanwendung erheblich. Vertiefte Kenntnisse der Webserververwaltung für die Anwendungsbereitstellung sind nicht erforderlich. Daher wird erwartet, dass viele Systemersteller, Datenwissenschaftler und UI-Designer das System bereits mit ihrem vorhandenen Wissen nutzen können. Darüber hinaus bietet der beschriebene Ansatz Kompatibilität mit einer Vielzahl von Endbenutzergeräten und vorhandenen Infrastrukturen bei gleichzeitig hoher technischer Skalierbarkeit. Da es sich um eine Serveranwendung handelt, kann das Toolkit in öffentlichen Clouds und als lokale Standardinstallation vor Ort ausgeführt werden. Wenn das Toolkit nur von wenigen Benutzern verwendet werden soll, kann es alternativ auch auf einem einzelnen Computer ausgeführt werden. In Bezug auf die Gerätekompatibilität mit Endbenutzern ermöglicht die webbasierte Schnittstelle die geräteübergreifende Verwendung, z. B. auf Computern, Smartphones oder Tablets. Abgesehen von Kompatibilitätsthemen folgt die Installation des Toolkits der Logik einer Django-App und ist mit einem Standard-Python-Paket vergleichbar. Daher kann eine Bereitstellung innerhalb von Minuten erfolgen. Schließlich behalten die bisher getroffenen Entwurfsentscheidungen die volle Flexibilität in Bezug auf alle im nächsten Schritt abgeleiteten Funktionskomponenten.

#### **Toolkit-Komponenten**

Basierend auf dem entwickelten Implementierungskonzept und der Idee eines modularisierten Toolkits wurden Komponenten, die die beabsichtigten Toolkit-Funktionen enthalten, als nachfolgender Schritt definiert. Durch Spiegeln der Ideen des konzeptionellen Rahmens werden ein Datenmanagement, ein Modellmanagement und eine Erklärungskomponente realisiert. Dabei entsprechen die ersten beiden der algorithmischen Dimension und enthalten die erforderlichen Funktionen zum Umgang mit Daten und ML-Modellen. Typische Vorgänge sind Datensatzverarbeitung, automatisches

Modelltraining und Zugriff auf Modellergebnisse. Darauf aufbauend realisiert die Erklärungskomponente alle relevanten Aspekte für die Generierung von Erklärungen. Zu diesem Zweck greift die Komponente auf konfigurierte Modelle und Daten zu, um die Benutzeroberfläche des Endbenutzers zu füllen.

Das gesamte Zusammenspiel der Komponenten funktioniert, indem ein Eingabedatensatz, ein Modell, erforderliche Kontextinformationen und die entsprechenden Erklärungen innerhalb der internen Logik des Toolkits (als Anwendungsfall bezeichnet) miteinander verknüpft werden. Für jeden Anwendungsfall richtet das System intern eine Umgebung ein, die aus Einstellungen, Daten und Modelldateien besteht, die alle erforderlichen Konfigurationen enthalten. Diese Informationen werden von den einzelnen Komponenten gespeichert, einschließlich Zwischenergebnissen, und ermöglichen die sofortige Generierung von Erklärungen auf der Benutzeroberfläche. Wenn Sie die Perspektive für die einzelnen Komponenten wechseln, wird jede einzeln implementiert und erfordert keine anderen Toolkit-Teile, um zu funktionieren. Dies wird durch die beschriebenen Einstellungsdateien realisiert, in denen das gesamte Toolkit gespeichert und fallspezifische Parameter verwendet werden. Die standardisierten Methoden, die von jeder Komponente verfügbar gemacht werden, erfordern Informationen, die in diesen Einstellungsdateien gespeichert sind. Anschließend greifen Methoden in jeder Komponente auf diese Dateien zu, führen ihre Operationen aus und geben Ausgaben an sie zurück. Der Inhalt von Einstellungsdateien kann jedoch auch manuell eingegeben werden oder von anderen Anwendungen außerhalb des Toolkits aufgerufen werden, was eine flexible Interoperabilität ermöglicht. Beim weiteren Drilldown auf die einzelnen Vorgänge jeder Komponente wird der Zugriff auf die bereitgestellten Methoden durch klar definierte Funktionsaufrufe standardisiert. Dadurch werden alle internen Prozesse für den Rest des Systems ausgeblendet, und nur auf relevante Ausgabeerzeugungsvorgänge kann zugegriffen werden. Eine ähnliche Standardisierung ist auf der UI-Seite gewährleistet. Um die Benutzeroberfläche zu füllen, werden variable Container verwendet, um definierte Daten mithilfe der Django-Vorlagenlogik an die webbasierte Oberfläche zu übergeben. Benutzeroberflächendesigner können auf diese Informationen zugreifen, indem sie eine variable Logik innerhalb einer regulären HTML-Seite verwenden. Infolgedessen können die von den Komponenten generierten Erklärungen flexibel neu angeordnet und mithilfe von HTML, CSS und JavaScript in eine vollständig flexible Webseite eingebettet werden.

Mit dem beschriebenen Komponentendesign wurden mehrere Kriterien aus der Software-Dimension implementiert, um ein qualitativ hochwertiges Toolkit zu gewährleisten. Erstens wird über die zuvor beschriebene technische Skalierbarkeit basierend auf der Webanwendung hinaus die gleiche aus funktionaler Sicht garantiert. Die im Toolkit beschriebene Anwendungsfalllogik ermöglicht das Einrichten beliebiger Szenarien basierend auf linearer oder logistischer Regression. Die einzige Einschränkung wird durch die Hardware der Maschine festgelegt, auf der das Toolkit ausgeführt wird, d. H. Speicherkapazitäten, die die Datenmenge begrenzen, die verarbeitet werden kann, oder die Anzahl paralleler Anforderungen, die von einem Server selbst verarbeitet werden können. Darüber hinaus gewährleistet die beschriebene Logik unter Verwendung

der Einstellungsdateien eine flexible Kombination verschiedener Komponenten, Interoperabilität und Erweiterbarkeit des Systems, da alle Systemfunktionen unabhängig voneinander implementiert wurden. Durch die Bereitstellung klar definierter Funktionsaufrufe ist die relevante Funktionalität innerhalb einer standardisierten Schnittstelle für Systemhersteller, ML-Entwickler und Webdesigner leicht zugänglich. Dies berücksichtigt auch den UI-Zugriff, der die beschriebenen variablen Container nutzt. Letzteres implementiert dabei gleichzeitig die erforderliche Aufgabentrennung zwischen UI und Erklärungsgenerierung.

#### Erläuterung und Anwendungsfallkonfiguration

Nach der Beschreibung der zentralen Merkmale des Toolkit-Designs wird nun die Perspektive auf Endbenutzer beleuchtet. Daher beschreiben alle im Folgenden beschriebenen Funktionen das Toolkit, wie es auf seiner Benutzeroberfläche sichtbar ist. Als erster Schritt zum Generieren von Erklärungen muss das Toolkit für ein gewünschtes Anwendungsszenario konfiguriert werden. Dies folgt der zuvor beschriebenen Anwendungsfalllogik. Außerdem kann auf das Setup über die Seite mit den Entwicklereinstellungen auf der Benutzeroberfläche zugegriffen werden. Die Seite ist in fünf Abschnitte unterteilt, die ausgefüllt werden müssen, und führt die Benutzer durch eine vollständige Konfiguration, um eine ordnungsgemäße Einrichtung sicherzustellen. Für einen zuvor eingerichteten Anwendungsfall kann jeder Abschnitt auch einzeln konfiguriert werden.

Der erste Abschnitt auf der Seite mit den Entwicklereinstellungen befasst sich mit der Auswahl von Anwendungsfällen. Hier können Benutzer entweder einen neuen Anwendungsfall erstellen oder einen vorhandenen auswählen. Jeder Anwendungsfall hat einen individuellen Namen, unter dem auf ihn zugegriffen werden kann. Zusätzlich muss hier der verwendete Modelltyp angegeben werden. Nach einer entsprechenden Auswahl werden im zweiten Abschnitt der Seite die entsprechenden Eingabedatenmerkmale für den ausgewählten Anwendungsfall definiert. Hierzu können entweder vorhandene Features geändert, ergänzt oder ein neuer Datensatz eingerichtet werden. Benutzer können die Namen, Beschreibungen und Typen der Eingabedatenfelder eingeben, die dem verwendeten Datensatz entsprechen. Wenn vorhandene Funktionen geändert werden, werden die aktuellen Datenfeldnamen, Beschreibungen und Typen angezeigt. Nach der erfolgreichen Konfiguration des Datasets müssen Benutzer im dritten Abschnitt die erforderlichen Kontextinformationen zu den verwendeten Daten und dem verwendeten Modell einrichten. Details zu Zweck und Inhalt dieser Eingabe werden im nächsten Kapitel zur Generierung von Erklärungen beschrieben. Nach Abschluss des vierten Abschnitts sind einige zusätzliche allgemeine Informationen für eine verbesserte Generierung von Texterklärungen erforderlich. Ein geeigneter Name, der den Datensatz beschreibt, zeichnet die gewünschte Dezimalrundung für die Anzeige von Zahlen auf. Im Fall einer logistischen Regression müssen positive und negative Merkmalswerte definiert werden. Die Hauptabsicht dieser Konfiguration besteht darin, die Texterklärungen für nicht technische Benutzer lesbarer und weniger abstrakt zu machen. Im letzten Abschnitt müssen die tatsächlichen Daten und das Modell konfiguriert werden. Die minimal erforderliche Eingabe ist ein Dateipfad zu einem Datensatz, der für das Modelltraining verwendet werden soll. Nach dem Speichern dieser Informationen trainiert das Toolkit ein Modell und generiert darauf basierend automatisch Erklärungen. Alternativ kann stattdessen auch ein vorhandenes Modell verwendet werden. Hierzu können eine im JSON-Format von Statsmodels gespeicherte vorgefertigte Modelldatei und die entsprechenden Trainingsdaten in einem h5-Format direkt importiert werden.

#### Erläuterung Generierung und Endbenutzeroberfläche

Wie bereits erwähnt, werden alle Prozesse zur Generierung von Erklärungen in der Erklärungskomponente implementiert. Um die Vielfalt der Funktionen zu berücksichtigen, die gemäß den identifizierten Literaturkriterien implementiert werden müssen, wird eine weitere Aufteilung in fünf Module eingeführt. Die allgemeinen Grundsätze für das Komponentendesign gelten auch für diese neu eingeführten Module.

Bevor die Funktionalität jedes Moduls einzeln beschrieben wird, werden einige Gemeinsamkeiten bei den Implementierungsmerkmalen und die entsprechende Erfüllung der identifizierten Erklärungskriterien definiert. Zunächst ruft jedes Erklärungsmodul seinen Inhalt automatisch aus den Daten- und Modellkomponenten des Toolkits ab, um die Richtigkeit des angezeigten Inhalts durch das Design sicherzustellen. Ausnahmen sind die Namen der Datenmerkmale, Beschreibungen und alle kontextbezogenen Hintergrundinformationen für einen konfigurierten Anwendungsfall. Die zuvor beschriebene Seite mit den Entwicklereinstellungen bietet jedoch eine geführte Konfiguration für diese Eingaben auf protokollähnliche Weise, sodass auch deren Richtigkeit so gut wie möglich gewährleistet ist.

Zweitens verwenden alle Module reaktionsfähige UI-Elemente, um kognitiv überforderte Benutzer zu vermeiden, indem die verfügbaren Informationen reduziert werden. Darüber hinaus besteht der zweite Zweck von UI-Elementen darin, unterschiedliche Erklärungsanforderungen in den verschiedenen Phasen des Erklärungsprozesses zu berücksichtigen. Einige Elemente der Benutzeroberfläche werden zunächst ausgeblendet, da sie Informationen enthalten, die für die tägliche Verwendung des Toolkits nicht erforderlich sind. Daher werden Benutzer angesprochen, die sich in einem späteren Stadium des Erklärungsprozesses befinden und bereits mit dem Toolkit vertraut sind, da erwartet wird, dass sie auf lange Sicht das größte Publikum sind. Dies erklärt das Prinzip, relevante Informationen am einfachsten anzuzeigen. Um jedoch auch zu berücksichtigen, dass Benutzer die Benutzeroberfläche zum ersten Mal bzw. nach einer langen Zeit auf einer mittleren Ebene erkunden, können relevante zusätzliche Informationen bei Bedarf erweitert werden.

Drittens enthalten alle Module mit Ausnahme des ersten einen erweiterbaren Unterabschnitt (angezeigt als "Verwendung dieser Informationen"), der detaillierte Erklärungen

für die verwendete Terminologie und die bereitgestellten Funktionen des jeweiligen Moduls enthält. Falls die Funktionalität statistische Beziehungen beinhaltet, werden diese anhand konkreter Datenbeschreibungen und -nummern aus dem jeweiligen Abschnitt und Anwendungsfall erläutert und anhand von Beispielen unterstrichen. Mit diesen Informationen wird auch von Erstbenutzern erwartet, dass sie die Benutzeroberfläche verstehen. Schließlich wird sichergestellt, dass alle potenziellen statistischen Zusammenhänge in einen angemessenen Kontext gestellt und mit qualitativen Details angereichert werden. Aufbauend auf diesen Standardkriterien werden nun die einzelnen Module beschrieben, wobei in jedem der folgenden Unterkapitel ein Modul aufgeführt ist.

#### Kontextinformationen

Als erster Teil des Erklärungs-Frontends soll im Abschnitt Kontextinformationen (CI) eine Einführung in das erläuterte Modell und seinen Kontext gegeben werden. Hier sind Informationen zu den relevanten Hintergrunddetails über die Themen Modellziel, Eingabedaten, Vorhersagebedeutung und verwendeter Algorithmus strukturiert. Alle Details mit Ausnahme des Modellziels werden zunächst ausgeblendet und können bei Bedarf erweitert werden, um die Orientierung weiter zu vereinfachen.

Die angezeigten Informationen enthalten alle relevanten Kriterien, die zuvor in Tabelle 2 wurden. Dabei sollten in der Literatur identifizierte Benutzerfragen zu Hintergrundinformationen beantwortet werden. Darüber hinaus werden mehrere funktionale Ziele erfüllt. Erstens wird erwartet, dass der Abschnitt die gesamte Benutzeroberfläche vertrauenswürdiger macht, da Benutzer sich über das Modell informieren und die Ausgaben in einen geeigneten Kontext stellen können Dies führt auch zu einem erhöhten Vertrauen in die spätere Entscheidungsfindung. Zweitens können die von den Prüfern verlangten Informationen hier so angegeben werden, dass der Abschnitt zur Einhaltung der einschlägigen Vorschriften und Bestimmungen beitragen kann. Drittens wurde bei der Eingabe dieser Informationen durch Datenwissenschaftler ein separater Abschnitt zur Verwendung der Ausgabe hinzugefügt, um Informationen zu zugrunde liegenden Theorien und Modellübertragungsoptionen bereitzustellen. Diese Erkenntnisse können von Endbenutzern wieder genutzt werden.

#### Globale Modellerklärungen

Das Ziel der globalen Modellerklärungen (GME) besteht darin, Transparenz über die allgemeine Logik des Output-Generierungsprozesses zu schaffen. Zu diesem Zweck werden alle Eingabefunktionen in Feldern aufgelistet, die numerisch und nicht numerisch strukturiert sind. In jedem Feld wird die Auswirkung eines Features auf die Ausgabe angezeigt. Für numerische Eingaben wird eine marginale Auswirkung bereitgestellt, und für nicht numerische Merkmale wird der Einfluss der Merkmalsebenen im Vergleich zu einer Grundlinienebene angegeben. Um auf eine Funktionsbeschreibung zuzugreifen, können Benutzer mit der Maus über Fragezeichen-Symbole neben dem

Funktionsnamen fahren, wodurch ein Tooltip ausgelöst wird. Darüber hinaus werden die Merkmale entsprechend sortiert, um die Größenordnungen der Auswirkungen auf die Ausgabe leichter identifizieren zu können. Abgesehen davon werden alle Elemente gleich angezeigt, so dass keine voreingenommene Auswahl der Ursachen gefördert wird.

Die bereitgestellte Funktionalität erfüllt wieder mehrere Erklärungskriterien. Erstens ermöglichen die Informationen den Benutzern, die beschriebenen Fragen zu Warum, Warum nicht und Anleitungen zu beantworten, da vollständige Transparenz über die Ausgabeerzeugung bereitgestellt wird. Darüber hinaus sind die freie Ursachenauswahl und das kontrafaktische Denken möglich, da Benutzer die Funktionen, an denen sie interessiert sind, im Vergleich zu ihren gewünschten Erdungen ohne Einschränkungen untersuchen können. Da schließlich auf die vollständige Modelllogik zugegriffen werden kann, sind alle Anforderungen erfüllt, die eine solche Transparenz erfordert. Somit werden Fairness-Urteile, die Einhaltung von Bestimmungen, die Identifizierung von Kausalitäten und Möglichkeiten zur Interpretation der zugrunde liegenden Theorien sichergestellt.

#### Vorhersage-Rechner

Als dritter Teil der Erklärungs-Benutzeroberfläche soll der Vorhersage-Rechner (PC) die Abfrage des Modells mit beliebigen Eingabewerten ermöglichen, während die entsprechende Ausgabe erhalten wird. Auf der Benutzeroberfläche wird basierend auf dem Datensatz und dem konfigurierten Modell automatisch ein Formular generiert, in dem alle Eingabefunktionen und ihre Ebenen aufgelistet sind. Nach Eingabe der gewünschten Werte in das Formular können Benutzer auf eine Schaltfläche klicken und die zurückgegebene Modellvorhersage für die ausgewählten Eingabewerte erhalten. Wenn Sie mit der Maus über das Ausgabeergebnis fahren, werden dessen Bestandteile weiter angezeigt, wobei auf die Auswirkungen des GME zuvor Bezug genommen wird.

Die Hauptfunktionalität dieses Teils besteht darin, die GME durch Berechnungen für Was-wäre-wenn-Fragen zu ergänzen. Da beliebige Eingabewerte angegeben werden können, haben Benutzer die Möglichkeit, das zugrunde liegende Modell flexibel abzufragen. Daher sind bis zu einem gewissen Grad die Ursachenauswahl und das kontrafaktische Denken ähnlich wie bei der GME gewährleistet. Da der PC eine Anwendung des GME ist, indem er mit einer automatischen Berechnung angereichert wird, trägt dieser Abschnitt zu den ähnlichen funktionalen Zielen bei, die bereits im Kontext des vorherigen Abschnitts beschrieben wurden.

#### Kontrafaktische Beispiele

Das vierte Modul zu kontrafaktischen Beispielen (CFE) soll den Benutzern ein praktischeres Verständnis typischer Merkmalswerte vermitteln, die eine bestimmte Vorhersage verursachen. Um dies zu realisieren, können Benutzer einen Vorhersagewert ermitteln und Datensatzdatensätze abfragen, die eine ähnliche oder nahe Ausgabe haben. Insgesamt sollten diese Beispiele den Benutzern ein besseres intuitives Gefühl dafür vermitteln, welche Funktionsstufen zu einem bestimmten Ausgabewert führen, indem der Ansatz der Erläuterung anhand eines Beispiels verwendet wird. In diesem Zusammenhang sollte es als Add-On zu GME und PC verstanden werden, ohne statistische Beziehungen aufzuweisen. Daher erweitert die Funktionalität die zuvor bereitgestellten Erklärungen zu Warum und Warum-Nicht und ermöglicht zusätzlich direkte Erklärungen zur Vorgehensweise. Da sachliche Aufzeichnungen gezeigt werden, sollten die in den vorherigen Modulen bereitgestellten Beziehungen bestätigt und anhand tatsächlicher Beispiele greifbarer gemacht werden. Daher wird erwartet, dass dies auch die Vertrauenswürdigkeit und das Vertrauen in das System erhöht.

#### **Datensatz-Explorer**

Der letzte Abschnitt der Erklärungsseite soll einen Überblick über die verwendeten Trainingsdatenfunktionen und ihre entsprechenden Wertverteilungen geben. Zu diesem Zweck listet der Datensatz Explorer alle Funktionen auf, die nach numerischen und nicht numerischen Merkmalen strukturiert sind. Die grundlegenden deskriptiven statistischen Parameter Durchschnitt, Median, oberes Quartil, unteres Quartil, Minimum und Maximum werden für numerische Daten angezeigt. Bei nicht numerischen Merkmalen werden die relative und absolute Häufigkeit für jede Merkmalsebene angezeigt. Ähnlich wie bei der GME wird jede Funktion durch eine kurze Beschreibung erweitert, auf die Benutzer zugreifen können, indem Sie den Mauszeiger über ein Fragezeichen neben dem Funktionsnamen bewegen.

Ähnlich wie beim CI soll in diesem Abschnitt wichtige Hintergrundinformationen zum Modell bereitgestellt werden, um den Erklärenden vertrauenswürdiger zu machen und den Benutzern das Vertrauen zu geben, Entscheidungen zu treffen. Darüber hinaus werden durch die Bereitstellung von Transparenz für den Datensatz mehrere funktionale Ziele erfüllt, die diese Transparenz erfordern. Zunächst können Verzerrungen in den Trainingsdaten festgestellt werden, die der Fairness entgegenwirken. Zweitens wird die Einhaltung von Gesetzen und Bestimmungen sichergestellt, die eine Prüfung des Datensatzes erfordern, z. B. die Erkennung von Datenschutzproblemen. Drittens können Modellübertragungsmöglichkeiten durch Untersuchen des Datensatzes erhalten werden.

#### 2.5.3 Validierung des Demonstrators

Die Validierung des IT-Demonstrators erfolgte in drei Schritten. Zunächst wurde der Demonstrator interessierten Unternehmen aus dem PA vorgestellt und im Rahmen von Experteninterviews im Januar 2021 besprochen. Die Interviews fokussierten den Grundsätzlichen Aufbau, die Funktionsweise und die Nutzbarkeit des Demonstrators. Das Feedback der Experten wurde in den Demonstrator eingearbeitet.

Im Rahmen des Abschlusstreffens am 25.02.2021 wurde der IT-Demonstrator mit Hilfe eines Fokusgruppeninterviews hinsichtlich seiner Praxistauglichkeit geprüft (Soll-Ist-Abgleich). Diese Validierung des Navigators fokussierte inhaltliche Aspekte wie Hindernisse und Hemmnisse bei der Umsetzung von Business Analytics, die im IT-Demonstrator betrachteten Business Analytics Algorithmen (Lineare Regression, Logistische Regression, Entscheidungsbäume), sowie die Praxistauglichkeit der vorgeschlagenen Maßnahmen. Die diskutierten Aspekte wurden anschließend sowohl im IT-Demonstrator überarbeitet sowie auch im Praxisleitfaden und in der Anleitung zur Steigerung der Akzeptanz. Folgende Tabelle gibt Aufschluss über Nutzen, Potenziale und Umsetzbarkeit der einzelnen Punkte des Navigators.

Tabelle 8: Praxistauglichkeit des Demonstrators und des Leitfadens

Inhaltlicher Aspekt	Nutzen	Feedback und Verbes- serungspotenzial	Praxistaug- lichkeit?
Grundsätzliche Zielsetzung und praktischer Nutzen des IT-Demonstrators	Verbesserung der Er- klärbarkeit von Business Analytics Algorithmen in kmU	Die Zielsetzung des IT- Demonstrators wird als sehr relevant angesehen; der IT-Demonstrator kann als Schulungsmaßnahme verwendet werden	<b>✓</b>
Aufbau und Handhabung des IT-Demonstrators	Einfache und intuitive Handhabung	Grundsätzliche Anmerkungen/ Verbesserungs- vorschläge zum Aufbau und zur Navigation wurden eingearbeitet	<b>√</b>
Auswahl der betrachteten Business Analytics Algorith- men	Im IT-Demonstrator wurden die Algorithmen Lineare Regression, Logistische Regression und Entscheidungsbäume gewählt, da diese die höchste praktische Relevanz besitzen	Die Algorithmen Lineare Regression, Logistische Regression und Entschei- dungsbäume wurden zu- sammen mit dem PA aus- gewählt und als relevant erachtet	<b>✓</b>
Inhaltliche Ausgestaltung der Handlungsempfehlun- gen im IT-Demonstrator	Handlungsempfehlungen sollen kmU dabei unter- stützen, Erklärungen zu den genannten Algorith- men effektiv umzusetzen	Grundsätzliche Anmerkungen/ Verbesserungs- vorschläge zu den Handlungsempfehlungen wurden eingearbeitet	<b>✓</b>

Inhaltlicher Aspekt	Nutzen	Feedback und Verbes- serungspotenzial	Praxistaug- lichkeit?
Leitfaden "Steigerung der Akzeptanz von Business Analytics durch Erklärungen und Reduktion von Biases"	Der Leitfaden gibt eine kmU-gerechte Übersicht über Maßnahmen zur Steigerung der Akzep- tanz und Reduktion von Biases	Grundsätzliche Anmerkungen/ Verbesserungs- vorschläge zu den Handlungsempfehlungen wurden eingearbeitet	<b>√</b>
Anleitung zur Steigerung der Akzeptanz mittels transparenter Erklärungen  Die Anleitung gibt eine kmU-gerechte Übersicht über Erklärungsmaßnahmen, da diese besonders aufwandsarm umsetzbar sind		Grundsätzliche Anmerkungen/ Verbesserungs- vorschläge zu den Handlungsempfehlungen wurden eingearbeitet	<b>√</b>

Für die abschließende Validierung des finalen IT-Demonstrators und des Leitfadens wurden mit zwei Fachexperten Fallbeispiele erarbeitet. Die Fallbeispiele wurden nachfolgend anonymisiert. Im Rahmen der Validierung wurde der IT-Demonstrator angewendet, um die Umsetzbarkeit von Business Analytics für unterschiedliche Unternehmensbereiche der Fallstudienpartner zu evaluieren (Controlling, Personal, Einkauf, Management). Dabei wurden die inhaltlichen Empfehlungen aus dem Demonstrator und aus dem Leitfaden kritisch reflektiert. Es konnten auf dieser Basis finale inhaltliche Anpassungen vorgenommen werden. Die Praxistauglichkeit der Ergebnisse wurde durch die Fachexperten als "sehr hoch" eingeschätzt.

#### 2.5.4 Fazit zu Arbeitspaket 5

In Arbeitspaket 5 wurden drei Business Analytics Algorithmen (Lineare Regression, Logistische Regression, Entscheidungsbäume) zur Verbesserung ihrer Erklärbarkeit in der Programmiersprache Python modifiziert. Der hierbei entwickelte IT-Demonstrator zur verbesserten Erklärbarkeit von Business Analytics Algorithmen wurde frei zugänglich publiziert. Des Weiteren erfolgte die Überführung und Publikation eines Praxisleitfadens auf Basis der im Forschungsvorhaben gewonnenen Erkenntnisse im Rahmen der Reihe "IPRI-Praxis" (Nr. 39 "Steigerung der Akzeptanz von Business Analytics durch Erklärungen und Reduktion von Biases"). Zusätzlich wurde eine "Anleitung zur Steigerung der Akzeptanz mittels transparenter Erklärungen" publiziert, die frei zum Download verfügbar ist. Alle Ergebnisse, also der Leitfaden, die Anleitung und der Demonstrator, wurden mit Unternehmen des PA validiert und weiterentwickelt, um eine möglichst hohe Praxistauglichkeit zu erzielen. Der Demonstrator ist unter folgendem Link einsehbar:

## 3. Verwendung der Zuwendung

Nachfolgend sind die Angaben zu den aus der Zuwendung finanzierten Ausgaben für Personenmonate des wissenschaftlich-technischen Personals gemäß Beleg über Beschäftigungszeiten (Einzelansatz A.1 des Finanzierungsplans), für Geräte (Einzelansatz B des Finanzierungsplans) und für Leistungen Dritter (Einzelansatz C des Finanzierungsplans) aufgeführt:

• wissenschaftlich-technisches Personal (Einzelansatz A.1 des Finanzierungsplans) Für die Durchführung der Arbeiten wurde Personal nach A1 (Wissenschaftliche Mitarbeiter) benötigt und eingesetzt:

Tabelle 9: Personaleinsatz nach A1 (Wissenschaftliche Mitarbeiter)

Jahr	IPRI	тим	Gesamt
2019	8,75 PM	9,00 PM	17,75 PM
2020	12,00 PM	11,25 PM	23,25 PM
2021	3,60 PM	1,75 PM	5,35 PM
Gesamt	24,35 PM	22,00 PM	46,35 PM

- Geräte (Einzelansatz B des Finanzierungsplans)
  - entfällt
- Leistungen Dritter (Einzelansatz C des Finanzierungsplans)
  - entfällt

# 4. Notwendigkeit und Angemessenheit der geleisteten Arbeit sowie Verwendung der Zuwendung

Die im Forschungsprojekt "ED³ – Integration der durch Business Analytics gewonnenen Erkenntnisse im Managementprozess durch die Sicherung deren Akzeptanz und verzerrungsfreien Interpretation" geleistete Arbeit entspricht in vollem Umfang dem bewilligten Antrag und war daher für die Durchführung des Vorhabens notwendig und angemessen.

Zur Ermittlung der aktuellen Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse im Managementprozess (im Rahmen von Arbeitspaket 1) erfolgte die Durchführung einer web-basierten Befragung von Experten und Anwendern im Bereich Business Analytics. Hierzu erfolgte eine Verteilung der Fragebogenstudie durch E-Mail-Anfrage von über 5500 Unternehmen, Verteilung an die Unternehmens des Projektbegleitenden Ausschusses und im Rahmen von öffentlichen XING- / LinkedIn-Postings. Zudem erfolgte eine semistrukturierte Befragung von BA-Systemanbietern. Die Datenerhebung und –auswertung ermöglichten die Beschreibung von Use Cases sowie die Konzeption einer Einsatzgebiet-Akzeptanz-Matrix.

Zur Entwicklung eines Modells zur Identifikation der Faktoren, die die Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse beeinflussen, (im Rahmen von Arbeitspaket 2) erfolgten Expertengespräche, ein Experten-Workshop und eine quantitativen Befragung von 51 Anwendern. Weiter wurde in diesem Arbeitspaket ein Experiment über Amazon Mturk durchgeführt. Als Ergebnis sind validierte Akzeptanzfaktoren von Business Analytics Erkenntnissen, ein validiertes Zusammenhangs- und Einflussfaktorenmodell sowie ein validiertes Akzeptanzmodell zu nennen.

Zur Identifikation von Biases, die im Kontext von durch Business Analytics gewonnenen Erkenntnissen aufkommen, (im Rahmen von Arbeitspaket 3) erfolgten Expertengespräche und -Workshops. Auf dieser Basis konnte eine Taxonomie 22 kognitiver Verzerrungen und 19 Handlungsempfehlungen zur Vermeidung dieser kognitiver Verzerrungen bei der Erstellung und Interpretation von Erkenntnissen aus Business Analytics abgeleitet werden.

Zur Identifikation von Maßnahmen in den Unternehmen zur Steigerung der Akzeptanz der durch Business Analytics gewonnen Erkenntnisse sowie zur Reduktion von Biases (im Rahmen von Arbeitspaket 4) erfolgte die Durchführung einer Vignettenstudie zur Validierung der identifizierten Erklärungsmethoden und zur Messung des Einflusses auf die Akzeptanz mit 222 Probanden. Auf dieser Basis war eine Ableitung von theoretischen Erkenntnissen und praktischen Handlungsempfehlungen zum Einsatz von Erklärungsmethoden auf Basis statistischer Auswertungen möglich.

Zur Entwicklung eines IT-Demonstrators sowie Schulungsmaßnahmen zur Steigerung der Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse sowie zur Reduktion von Biases (im Rahmen von Arbeitspaket 5) erfolgte die Entwicklung eines anwenderorientierten IT-Demonstrators. Dieser wurde ergänzt durch einen Praxisleitfaden inklusive Trainingskonzept, einer Anleitung zur Steigerung der Akzeptanz mittels transparenter Erklärungen sowie die Validierung aller Ergebnisse mit Unternehmen des PA.

Allen Arbeiten lagen zudem intensive Literaturaufarbeitungen zugrunde. Im Rahmen der vier Sitzungen des projektbegleitenden Ausschusses wurden die erreichten Zwischenergebnisse präsentiert und zur Diskussion gestellt. Expertengespräche dienten dazu, wichtige Informationen über praktische Rahmenbedingungen und unternehmensspezifische Anforderungen zu erheben.

Zur Verbreitung der Ergebnisse wurden unterschiedlichste Transfermaßnahmen durchgeführt (siehe Kapitel 6). Diese beinhalten u.a. die Durchführung von Webinaren, Seminaren, Workshops, Pressearbeit sowie praxisorientierte und wissenschaftliche Ergebnispublikationen. Zu nennen sind in diesem Kontext folgende Veröffentlichungen:

- Hupfer, G.; Künkele, S.; Seiter, M. (2021), Towards a Better Understanding on the Acceptance of Black-Box Algorithms in Accounting – An Experimental Study on the Weighting of Black-Box Information in Performance Evaluation.
- IPRI, TUM (Hrsg. 2021), Leitfaden zur Steigerung der Akzeptanz mittels transparenter Entscheidungen [Internetdokument].
- Rusch, M. (2021), Akzeptanz algorithmusbasierter Erkenntnisse Wie Unternehmen die Einführung von Business Analytics zum Erfolg führen, in: ERP Management, 17 Jg., 2021, Nr. 1, S. 21-23.
- Wytopil, B. (2021), Steigerung der Akzeptanz von Business Analytics durch Erklärungen und Reduktion von Biases, IPRI-Praxispaper Nr. 40, 2021.

Das Erarbeiten der Ergebnisse war für das IPRI und die TUM mit einem hohen personellen Aufwand verbunden. Vor diesem Hintergrund beurteilen die Forschungseinrichtungen die geleistete Arbeit als inhaltlich angemessen und förderungswürdig. Auch die Höhe der Zuwendung erscheint in Anbetracht der erzielten Ergebnisse und des geleisteten Personalaufwandes angemessen.

# 5. Nutzen, Innovationsbeitrag und Anwendungsmöglichkeiten der erzielten Ergebnisse

# 5.1 Wissenschaftlich-technischer und wirtschaftlicher Nutzen der erzielten Ergebnisse

Ziel des Forschungsvorhabens ED³ war es, die Unternehmen der produzierenden Industrie, u.a. im Maschinen- und Anlagenbau, zu befähigen, die durch Business Analytics gewonnenen Erkenntnisse erfolgreich zu nutzen. Damit sollten sie in die Lage versetzt werden, Entscheidungen evidenzbasiert zu treffen und somit subjektive, unbewusst verzerrte Entscheidungen zu reduzieren.

Im Projekt wurden zu Beginn die Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse in den verschiedenen Phasen des Managementprozesses und deren Einflussfaktoren in den produzierenden Unternehmen ermittelt. Das Ergebnis ist eine Einsatzgebiet-Akzeptanz-Matrix der aktuellen Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse im Managementprozess produzierender kmU. Hierauf aufbauend erfolgte die Entwicklung eines Modells zur Identifikation der Faktoren, die die Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse beeinflussen. Auf dieser Basis konnte ein Zusammenhangs- und Einflussfaktorenmodell entwickelt und validiert werden. Alle Erkenntnisse wurden zu einem validierten Akzeptanzmodell zusammengeführt.

Anschließend wurden Biases im Kontext der durch Business Analytics gewonnenen Erkenntnisse auf Managementebene identifiziert und strukturiert. Aus diesen Erkenntnissen wurden Implikationen zur Steigerung der Akzeptanz und Reduktion von Biases für die Nutzung von durch Business Analytics gewonnenen Erkenntnissen abgeleitet. Als wesentliches Ergebnis ist hier der Katalog validierter Biases im Kontext von Business Analytics zu nennen. Um diese Ergebnisse praxistauglich zu gestalten, wurden Maßnahmen zur Steigerung der Akzeptanz und zur Reduktion von Biases abgeleitet und validiert.

Alle Ergebnisse des Projekts wurden für kmU im Rahmen eines IT-Demonstrators aufbereitet, welches für Schulungszwecke genutzt werden kann. Weiter zu nennen sind an dieser Stelle der Praxisleitfaden "Steigerung der Akzeptant von Business Analytics durch Erklärungen und Reduktion von Biases", welcher im Rahmen der Reihe "IPRI-Praxis" publiziert wurde (IPRI-Praxispaper Nr. 40), sowie die frei verfügbare "Anleitung zur Steigerung der Akzeptanz mittels transparenter Erklärungen", die interessierten Unternehmen als Download zur Verfügung steht. Zur Absicherung der mit der Einführung von Business Analytics verbundenen hohen Investitionen (IT-Infrastruktur, Mitarbeiterschulungen etc.) ist eine hohe Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse sowie eine verzerrungsfreie Interpretation notwendig. Eine Schulung auf Basis des IT-Demonstrators befähigt kmU dazu, die durch Business Analytics

gewonnenen Erkenntnisse für das Management nutzbar zu machen. Durch das Projekt werden kmU damit in die Lage versetzt, die Potenziale dieser durch Business Analytics gewonnenen Erkenntnisse zielführend einzusetzen.

Aus den Ergebnissen des Projekts ergibt sich ein unmittelbarer und mittelbarer Nutzen. Der Nutzen der angestrebten Forschungsergebnisse ist insgesamt als sehr hoch einzuschätzen. Der unmittelbare Nutzen ergibt sich aus den folgenden Punkten:

- Mit der Reduktion von Biases im Kontext von Business Analytics bei Unternehmensentscheidern kann das volle Potenzial von Business Analytics genutzt werden. Dies führt anschließend zu einer effektiven Nutzung der Unternehmensdaten und den aufgebrachten Ressourcen, welche für die Umsetzung von Business Analytics eingesetzt wurden.
- Erst mit der Verbesserung der Akzeptanz von Business Analytics bei Unternehmensentscheidern kann das volle Potenzial von Business Analytics genutzt werden. Dies führt ebenfalls zu einer effektiven Nutzung der Unternehmensdaten und den aufgebrachten Ressourcen, die für die Umsetzung von Business Analytics eingesetzt wurden.

Die Ergebnisse bieten kmU folgenden mittelbaren Nutzen:

- Aufgrund der gesteigerten Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse in Unternehmen, werden auch andere Bereiche in Unternehmen die Möglichkeiten von Business Analytics umsetzen.
- Mittelbarer Nutzen besteht in der verbesserten Kenntnis der Biases, die in der Unternehmenssteuerung vorhanden sind sowie der Möglichkeit zur objektiveren Entscheidungsfindung der Geschäftsprozesse.
- Das Projekt schafft Transparenz über Zusammenhänge und Gestaltungsmöglichkeiten im Unternehmen. Damit wird das Management in die Lage versetzt, die Profitabilität ihrer Geschäftsfelder direkt zu steuern und Standards am Markt zu setzen.

# 5.2 Innovativer Beitrag und industrielle Anwendungsmöglichkeiten der erzielten Ergebnisse

Die Projektergebnisse leisten zwei zentrale Innovationsbeiträge. Der erste innovative Aspekt besteht in der Steigerung der Akzeptanz der durch Business Analytics gewonnenen Erkenntnisse bei den Entscheidungsträgern in den kmU. Bedingt durch die Komplexität der Anwendung von Business Analytics werden die gewonnenen Erkenntnisse in der Praxis bisher nur in einem äußerst geringen Umfang gezielt genutzt (Unterstützung bzw. Generierung der Entscheidungsfindung). Stattdessen gehen betriebliche Business Analytics Anwendungen oftmals nicht über den Pilotprojekt-Status hinaus. Die durch Business Analytics gewonnenen Erkenntnisse bieten kmU der produzierenden Industrie die Möglichkeit, ihre Profitabilität, durch die Optimierung der gesamten Wertkette zu steigern. Das Ziel von Business Analytics ist es, Problemstellungen im gesamten Managementzyklus von Planung, Steuerung und Kontrolle evidenzbasiert zu lösen. Unter Evidenzen werden begründete, objektive Einsichten in einen

Sachverhalt verstanden. Diese Evidenzen werden auf Basis von Daten aus verschiedensten Bereichen innerhalb und außerhalb des Unternehmens mittels Algorithmen aus den Bereichen Statistik, Data Mining und Machine Learning gewonnen. Durch die Anwendung von Business Analytics können Entscheidungen faktenbasiert getroffen und komplexe Szenarios visualisiert werden. Business Analytics wird inzwischen verbreitet bei kmU in einer Vielzahl von Abteilungen eingesetzt z.B. dem Controlling, dem Vertrieb, der Logistik, der Produktion oder im Bereich Forschung & Entwicklung. Die Reduzierung der bei den betrieblichen Entscheidungsträgern vorliegenden Akzeptanzhürden hinsichtlich der durch Business Analytics gewonnenen Erkenntnisse sowie die Identifikation und Einschränkung damit verbundener Biases ist Grundlage für die gewinnbringende Nutzung von Business Analytics.

Der zweite zentrale Innovationsbeitrag besteht in der Senkung von Biases bei Entscheidungsträgern der kmU. Bei einer datengetriebenen Entscheidungsfindung wird es notwendiger, den Einfluss von menschlichen Faktoren zu senken, da es aufgrund von Verzerrungen oder Vorurteilen, sogenannten Biases, zu Fehleinschätzungen kommt, die wiederrum gravierende Auswirkungen auf die finanzielle Gesundheit des Unternehmens haben können. In bisherigen Untersuchungen und Forschungsvorhaben wurden zumeist nur die Biases in allgemeinen Ursache-Wirkungsbeziehungen betrachtet und nicht für die Entscheidungen von Managern in kmU spezifiziert. Demgegenüber wurden in diesem Forschungsvorhaben die vorhandenen Biases auf den Entscheidungsebenen in Unternehmen für die erfolgreiche Nutzung von Business Analytics analysiert und Maßnahmen entwickelt, um diese zu reduzieren.

Insgesamt werden durch die Ergebnisse kmU dazu befähigt, mögliche Akzeptanz-hürden der durch Business Analytics gewonnenen Erkenntnisse und Biases in der Unternehmenssteuerung zu identifizieren und einzuschränken.

# 6. Plan zum Ergebnistransfer und Einschätzung zur Realisierbarkeit des Transferkonzepts

#### 6.1 Einschätzung zur Realisierbarkeit des Transferkonzepts

Um das wichtige Ziel der Verbreitung der Ergebnisse des Forschungsvorhabens in der Wirtschaft zu erreichen, wurden folgende Transfermaßnahmen während und nach der Projektbearbeitung durchgeführt. Die wesentlichen Maßnahmen zur Verbreitung der Projektergebnisse wurden dabei bereits während der Projektlaufzeit durchgeführt. Um jedoch die Anwendung der Erkenntnisse über die Projektlaufzeit hinaus sicherzustellen, werden insbesondere die Endergebnisse (Leitfaden, Zertifikatskurse, Business Analytics Vorlesung) noch eine weitere Zeit verfügbar sein. Dadurch wird gewährleistet, dass möglichst viele interessierte Parteien (KMU, Forschungseinrichtungen, Verbände etc.) von den Forschungsergebnissen partizipieren. Die Realisierbarkeit zum Ergebnistransfer kann folglich als sehr hoch eingeschätzt werden.

#### 6.2 Spezifische Transfermaßnahmen während der Projektlaufzeit

Tabelle 4: Transfermaßnahmen während der Projektlaufzeit

Maßnahme	Ziel	Maßnahme	Zeitraum/Datum
Einbezug künftiger Entscheidungsträger (fortgeschrittene Stu- denten des Studien- gangs Business Ana- lytics)	Frühzeitige Sensibilisierung zukünftiger Entscheidungsträ- ger hinsichtlich des Themas	Vorstellung in der Weiterbildung (Uni Ulm: Studiengang Business Analytics (SAPS)); Vorstellung im AK Industrie 4.0; Experimentalstudie (Veröffentlicht in: European Accounting Review)	Uni Ulm: 17.01.2020, 21.01.2021; AK 4.0: 11.11.2020
Treffen und Validie- rung mit dem Projekt- begleitenden Aus- schusses	<ul> <li>Validierung der Ergebnisse mit den Praxispartnern</li> <li>Übertragbarkeit der Ergebnisse auf praxisrelevante Problemstellungen</li> </ul>	4 Treffen im projektbegleiten- den Ausschuss (PA)	1. PA (11.07.19), 2. PA (31.01.20), 3. PA (01.07.20), 4. PA (26.02.21)
Vorstellung in Unter- nehmen	Überprüfung der Funktionalität	Live-Demonstration des IT- Tools auf der 4. Sitzung des PA sowie in gesonderten Ter- minen bei Mitgliedern des PA	4. PA-Sitzung am 26.02.2021; Einzeltermine am 12.03.2021 und 23.03.2021
Presse-/Öffentlich- keitsarbeit	Bekanntmachung des Projektes und weitere Verbreitung der Projektinhalte und -ergebnisse	<ul> <li>2x Pressemitteilung bei IDW online (Projektstart und Projektende)</li> <li>2x IPRI Journal</li> <li>2x IPRI Jahresbericht</li> </ul>	IDW: 15.07.2019 und 31.03.2021; IPRI Journal 2019 und 2020: IPRI Jahresbe- richt 2019 und 2020
Begleitende Schulun- gen bei Unternehmen und an den For- schungsinstituten	Optimale Anwendung durch Unternehmensvertreter	Zwei Workshops bei Unter- nehmen des PA	02.12.20 und 04.12.20

Maßnahme	Ziel	Maßnahme	Zeitraum/Datum
Präsenz im Internet	Fortlaufende Information über das Forschungsprojekt und die (Teil)-Ergebnisse	<ul> <li>IPRI-Webpräsenz</li> <li>Bekanntmachung des Projekts über Social Media, insbesondere LinkedIn</li> </ul>	Webpräsenz: Seit Projektstart; LinkedIn-Beiträge vom 06.08.2020, 01.12.2020, 16.02.2021, 05.03.2021
Präsentation der Zwischenergebnisse auf Workshops, Seminaren und Kolloquien bei den Forschungsstellen und Fachverbänden	Kontinuierlicher Informations- austausch mit Industriepart- nern	<ul> <li>Symposium Industrie 4.0 wegen Covid-19 ausgefallen, dafür 2. Sitzung des AK Industrie 4.0 in 2020</li> <li>Vorstellung des Projekts im Rahmen eines TUM Executive Education Vortrag</li> <li>Vorstellung des Projekts im Rahmen der Sitzung des Projektbegleitenden Ausschusses des Forschungsprojektes "ApC – Agiles projektbasiertes Crowdsourcing"</li> </ul>	AK Industrie 4.0: 11.11.2020; TUM Executive Education: 24.01.2020 ApC: 12.09.2019
Gezielte Ansprache potenziell interessier- ter Unternehmen über die Verbände	Verbreitung der Methodik auch in Unternehmen außer- halb des Projekts	Gezielte Ansprache über die IHK Ulm + Einladung zum Symposium des AK 4.0	Dezember 2020
Vorträge auf Tagun- gen, Kongressen und Kolloquien	Informationsverbreitung an weitere Unternehmen	Vorstellung auf Münchner Ma- nagement Kolloquium nicht möglich wegen Covid-19; Vortrag der Projektinhalte / ED3-Forschungsergebnisse im Kompetenzzentrum Indust- rie 4.0	27.05.2020
Handlungsleitfaden	Veröffentlichung des entwi- ckelten Trainingskonzeptes	<ul> <li>IPRI-Praxispaper Nr. 40         ("Steigerung der Akzeptant von Business Analytics durch Erklärungen und Reduktion von Biases")</li> <li>Anleitung zur Steigerung der Akzeptanz mittels transparenter Erklärungen</li> </ul>	März 2021
Integration in die universitäre Lehre	<ul> <li>Integration in das Seminar- programm Business Analy- tics</li> <li>Studienarbeiten</li> </ul>	<ul> <li>Uni Ulm: Studiengang Business Analytics (SAPS)</li> <li>TUM: Judgment and Strategic Decision Making Seminar → 14 Seminararbeiten als Prüfungsleistung des Seminars</li> <li>TUM: 4 Bachelorthesen und 4 Masterthesen zu Themen des Forschungsvorhabens</li> </ul>	Uni Ulm: 17.01.2020, 21.01.2021; TUM: WS19/20
Veröffentlichungen in Fachzeitschriften	Verbreitung der Ergebnisse	In den Fachzeitschriften:  ERP Management Ausgabe 2/2021  European Accounting Review, Special Issue 2021 (eingereicht)	ERP Manage- ment: März/April 2021;

## 6.3 Spezifische Transfermaßnahmen nach Abschluss des Vorhabens

Tabelle 5: Transfermaßnahmen nach Abschluss des Vorhabens

Tabelle 5: Transfermalsnanmen nach Abschluss des Vornabens			
Maßnahme	Ziel	Ort / Rahmen	Zeitraum
Gezielte Ansprache interessierter Unternehmen über die Verbände	Verbreitung der Methodik auch in Unternehmen außer- halb des Projekts	Ergebnisverbreitung über die IHK Ulm sowie die Wirtschaftsförderung Region Stuttgart	Ende 2021
Integration in die IPRI- Seminarreihe	Qualifizierung von Mitarbeitern aus kmU im Rahmen des IPRI Seminars "Business Analytics"	Integration in die IPRI-Semi- narreihe, buchbar über Insti- tutswebseite	Ab März 2021
AK4.0 (Arbeitskreis Industrie 4.0 - Betriebswirtschaftliche Fragestellungen im Fokus)	Verbreitung der Ergebnisse und deren Überführung in die praktische Anwendung	Vorstellung der Ergebnisse auf der 2. Sitzung des AK In- dustrie 4.0 in 2020; Integration der Ergebnisse (insb. Maß- nahmen zur Steigerung der Akzeptanz) auf zukünftigen Sitzungen des AK	11.11.2020 sowie auf zukünftigen Sitzungen ab 2021
Webinar	Qualifizierung von Mitarbeitern aus kmU	Integration in die IPRI-Webi- narreihe sowie Bekanntma- chung über LinkedIn; drei Ter- mine wurden bereits angebo- ten	02.12.20, 04.12.20 und 08.12.20
Verbreitung der Infor- mationen über Inter- netplattformen	Informationsverbreitung an weitere Unternehmen	Institutswebseiten des IPRI/TUM und LinkedIN	Ab März 2021
Aufnahme der Inhalte in Seminarprogramme für Industrievertreter	Gezieltes Informieren von interessierten Unternehmen	Ergebnisverbreitung im Rahmen der Executive Education des Lehrstuhls für Strategie und Organisation an der TUM für. Konkret in den Seminaren "Digital Transformation" sowie "Negotiation and Micropolitics"	Ab April 2021
Aufnahme in die aka- demische Lehre	Frühzeitige Schulung der zu- künftigen Unternehmen	Vorstellung des Projekts im Rahmen des Studiengangs Business Analytics der Uni Ulm im Januar 2020 und 2021 sowie dauerhafte Integration der Projektergebnisse in den Studiengang Business Analy- tics der Uni Ulm ab dem WS 21/22	Uni Ulm: 17.01.2020, 21.01.2021 sowie dauerhafte In- tegration ab dem WS 21/22

## 7. Forschungsstellen

# Forschungsstelle 1: IPRI – International Performance Research Institute gGmbH

IPRI wurde mit der Zielsetzung gegründet, Forschung auf dem Gebiet des Performance Management von Organisationen, Unternehmen und Unternehmensnetzwerken zu betreiben. Unter Leitung von Prof. Dr. Mischa Seiter untersucht IPRI in Zusammenarbeit mit anderen Forschungseinrichtungen und kleinen und mittelständischen Unternehmen die Wirkungszusammenhänge und Potenziale in den Bereichen Controlling, Finanzen, Logistik und Produktion. Forschungsschwerpunkt des Gründers Prof. Dr. Dr. h.c. Péter Horváth ist die Erarbeitung neuer Methoden im Bereich des Controllings und der Transfer dieser Ergebnisse in die Praxis.

Tabelle 10: IPRI – International Performance Research Institute gemeinnützige GmbH

Forschungsstelle	IPRI – International Performance Research Institute gemeinnützige GmbH
Anschrift	Königstraße 5, 70173 Stuttgart
Leitung der Forschungsstelle	Prof. Dr. Mischa Seiter
Kontakt	Tel.: 0711 - 620 32 680, www.ipri-institute.com

#### Forschungsstelle 2: Lehrstuhl für Strategie und Organisation (LSO)

Der Lehrstuhl für Strategie und Organisation der Technischen Universität München verfügt über langjährige Erfahrung im Bereich universitärer Forschung und in Praxisprojekten. Die Themen umfassen Innovationsforschung, das Verhalten in Organisationen, strategische Entscheidungsfindung und den Einfluss digitaler Technologien auf Organisationen.

Tabelle 11: Lehrstuhl für Strategie und Organisation (LSO)

Forschungsstelle	Lehrstuhl für Strategie und Organisation (LSO) an der Technischen Universität München
Anschrift	Arcisstraße 21, 80333 München
Leitung der Forschungsstelle	Prof. Dr. Isabell Welpe
Kontakt	Tel.: 089 – 289 – 24800, www.professors.wi.tum.de/strategy

#### 8. Förderhinweis

Das IGF-Vorhaben 20694 N der Forschungsvereinigung Institut für Energie- und Umwelttechnik e.V. - IUTA, Bliersheimer Straße 60, 47229 Duisburg wurde über die AiF im Rahmen des Programms zur Förderung der industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages gefördert.



Für die Förderung sei an dieser Stelle gedankt.

#### 9. Quellenverzeichnis

Abu-Doleh, Jamal; Weir, David (2007): Dimensions of performance appraisal systems in Jordanian private and public organizations. In: *The International Journal of Human Resource Management* 18 (1), S. 75–84.

Ahmad, Rusli; Azman Ali, Nur (2004): Performance appraisal decision in Malaysian public service. In: *Intl Jnl Public Sec Management* 17 (1), S. 48–64.

Ain, NoorUI; Vaia, Giovanni; DeLone, William H.; Waheed, Mehwish (2019): Two decades of research on business intelligence system adoption, utilization and success – A systematic literature review. In: *Decision Support Systems* 125, S. 113113.

Aloysius, John A.; Davis, Fred D.; Wilson, Darryl D.; Ross Taylor, A.; Kottemann, Jeffrey E. (2006): User acceptance of multi-criteria decision support systems: The impact of preference elicitation techniques. In: *European Journal of Operational Research* 169 (1), S. 273–285.

Arnold; Clark; Collier; Leech; Sutton (2006): The Differential Use and Effect of Knowledge-Based System Explanations in Novice and Expert Judgment Decisions. In: *MIS Quarterly* 30 (1), S. 79.

Arnold, Vicky; Clark, Nicole; Collier, Philip A.; Leech, Stewart A.; Sutton, Steve G. (2004): Explanation provision and use in an intelligent decision aid. In: *Int. J. Intell. Syst. Acc. Fin. Mgmt.* 12 (1), S. 5–27.

Arnott, David (2006): Cognitive biases and decision support systems development: a design science approach. In: *Information Systems Journal* 16 (1), S. 55–78.

Atzmüller, Christiane; Steiner, Peter M. (2010): Experimental Vignette Studies in Survey Research. In: *Methodology* 6 (3), S. 128–138.

Ayton, Peter; Hunt, Anne J.; Wright, George (1989): Psychological conceptions of randomness. In: *J. Behav. Decis. Making* 2 (4), S. 221–238.

Azadeh, A.; Saberi, M.; Rouzbahman, M.; Saberi, Z. (2013): An intelligent algorithm for performance evaluation of job stress and HSE factors in petrochemical plants with noise and uncertainty. In: *Journal of Loss Prevention in the Process Industries* 26 (1), S. 140–152.

Babcock, Linda; Loewenstein, George (1997): Explaining Bargaining Impasse: The Role of Self-Serving Biases. In: *Journal of Economic Perspectives* 11 (1), S. 109–126.

Badillo, Solveig; Banfai, Balazs; Birzele, Fabian; Davydov, Iakov I.; Hutchinson, Lucy; Kam-Thong, Tony et al. (2020): An Introduction to Machine Learning. In: *Clinical pharmacology and therapeutics* 107 (4), S. 871–885.

Barbour, Philippe; Griffin, Jessica; Hast, Adele; Pascal, Diane (1992): International directory of company histories. Detroit, London: St. James Press.

Barnes, James H. (1984): Cognitive biases and their impact on strategic planning. In: *Strat. Mgmt. J.* 5 (2), S. 129–137.

Berry, Dianne C.; Gillie, Tony; Banbury, Simon (1995): What do patients want to know: An empirical approach to explanation generation and validation. In: *Expert Systems with Applications* 8 (4), S. 419–428

Bilgic, Mustafa; Mooney, Raymond J. (2005a): Explaining Recommendations: Satisfaction vs. Promotion. In: *Beyond Personalization Workshop* (IUI), S. 1–6.

Bilgic, Mustafa; Mooney, Raymond J. (2005b): Explaining recommendations: Satisfaction vs. promotion. In: Beyond Personalization Workshop, IUI (Vol. 5), S. 153.

Bischoff, Stefan; Aier, Stephan; Haki, Mohammad Kazem; Winter, Robert (2015): Understanding Continuous Use of Business Intelligence Systems: A Mixed Methods Investigation. In: *Journal of Information Technology Theory and Application (JITTA)* 16 (2), S. 5–38.

Bol, Jasmijn C. (2010): The Determinants and Performance Effects of Managers' Performance Evaluation Biases. In: SSRN Journal.

Bol, Jasmijn C.; Kramer, Stephan; Maas, Victor S. (2016): How control system design affects performance evaluation compression: The role of information accuracy and outcome transparency. In: *Accounting, Organizations and Society* 51, S. 64–73.

Breiman, Leo (2001): Statistical Modeling: The Two Cultures (with comments and a rejoinder by the author). In: *Statist. Sci.* 16 (3), S. 199–231.

Bukszar, E.; Connolly, T. (1988): Hindsight Bias and Strategic Choice: Some Problems in learning from Experience. In: *Academy of Management Journal* 31 (3), S. 628–641.

Burmeister, Katrin; Schade, Christian (2007): Are entrepreneurs' decisions more biased? An experimental investigation of the susceptibility to status quo bias. In: *Journal of Business Venturing* 22 (3), S. 340–362.

Busenitz, Lowell W.; Barney, Jay B. (1997): Differences between entrepreneurs and managers in large organizations: Biases and heuristics in strategic decision-making. In: *Journal of Business Venturing* 12 (1), S. 9–30.

Bussone, Adrian; Stumpf, Simone; O'Sullivan, Dympna (2015): The Role of Explanations on Trust and Reliance in Clinical Decision Support Systems. In: International Conference on Healthcare 21.10.2015 - 23.10.2015, S. 160–169.

Camilleri, Adrian R.; Larrick, Richard P. (2014): Metric and Scale Design as Choice Architecture Tools. In: *Journal of Public Policy & Marketing* 33 (1), S. 108–125.

Castelo, Noah (2019): Blurring the Line Between Human and Machine: Marketing Artificial Intelligence.

Chandrasekaran, B.; Tanner, M. C.; Josephson, J. R. (1989): Explaining control strategies in problem solving. In: *IEEE Expert* 4 (1), S. 9–15.

Chang, Shuo; Harper, F. Maxwell; Terveen, Loren Gilbert: Crowd-Based Personalized Natural Language Explanations for Recommendations. In: Sen, Geyer et al. (Hg.) 2016 – Proceedings of the 10th ACM, S. 175–182.

Chen; Chiang; Storey (2012): Business Intelligence and Analytics: From Big Data to Big Impact. In: *MIS Quarterly* 36 (4), S. 1165.

Chen, Guoli; Crossland, Craig; Luo, Shuqing (2015): Making the same mistake all over again: CEO overconfidence and corporate resistance to corrective feedback. In: *Strat. Mgmt. J.* 36 (10), S. 1513–1535.

Chen, Li; Wang, Feng: Explaining Recommendations Based on Feature Sentiments in Product Reviews. In: Papadopoulos, Kuflik et al. (Hg.) 2017 – Proceedings of the 22nd International, S. 17–28.

Chpman, G. B.; Bergus, G. R.; Elstein, A. S. (1996): Order of Information Affects Clinical Judgment. In: *J. Behav. Decis. Making* 9 (3), S. 201–211.

Coba, Ludovik; Zanker, Markus; Rook, Laurens; Symeonidis, Panagiotis (2018 - 2018): Exploring Users' Perception of Collaborative Explanation Styles. In: 2018 IEEE 20th Conference on Business Informatics (CBI). 2018 IEEE 20th Conference on Business Informatics (CBI). Vienna, 11.07.2018 - 14.07.2018: IEEE, S. 70–78.

Cramer, Henriette; Evers, Vanessa; Ramlal, Satyan; van Someren, Maarten; Rutledge, Lloyd; Stash, Natalia et al. (2008): The effects of transparency on trust in and acceptance of a content-based art recommender. In: *User Model User-Adap Inter* 18 (5), S. 455–496.

Cripps, John D.; Meyer, Robert J. (1994): Heuristics and Biases in Timing the Replacement of Durable Products. In: *J CONSUM RES* 21 (2), S. 304.

Dai, Narisa Tianjing; Kuang, Xi; Tang, Guliang (2018): Differential Weighting of Objective Versus Subjective Measures in Performance Evaluation: Experimental Evidence. In: *European Accounting Review* 27 (1), S. 129–148.

Das, T. K.; Teng, Bing-Sheng (1999): Cognitive Biases and Strategic Decision Processes: An Integrative Perspective. In: *Journal of Management Studies* 36 (6), S. 757–778.

Davis, F. D. (1986): A technology acceptance model for empirically testing new end-user information systems: theory and results.

Dhaliwal, Jasbir S.; Benbasat, Izak (1996): The Use and Effects of Knowledge-Based System Explanations: Theoretical Foundations and a Framework for Empirical Evaluation. In: *Information Systems Research* 7 (3), S. 342–362.

Dietvorst, Berkeley J.; Simmons, Joseph P.; Massey, Cade (2015): Algorithm aversion: people erroneously avoid algorithms after seeing them err. In: *Journal of experimental psychology. General* 144 (1), S. 114–126.

Dobelli, Rolf (2018): Die Kunst des klaren Denkens. 52 Denkfehler, die Sie besser anderen überlassen. Ungekürzte Ausgabe. München: Deutscher Taschenbuch-Verlag (dtv, 34826).

Duhaime, Irene M.; Schwenk, Charles R. (1985): Conjectures on Cognitive Simplification in Acquisition and Divestment Decision Making. In: *The Academy of Management Review* 10 (2), S. 287.

Dulcic, Zelimir; Pavlic, Dino; Silic, Ivana (2012): Evaluating the Intended Use of Decision Support System (DSS) by Applying Technology Acceptance Model (TAM) in Business Organizations in Croatia. In: *Procedia - Social and Behavioral Sciences* 58, S. 1565–1575.

Ehrlich, Kate; Kirk, Susanna E.; Patterson, John; Rasmussen, Jamie C.; Ross, Steven I.; Gruen, Daniel M. (2011): Taking advice from intelligent systems. In: Pearl Pu, Michael Pazzani, Elisabeth André und Doug Riecken (Hg.): Proceedings of the 15th international conference on Intelligent user interfaces - IUI '11. the 15th international conference. Palo Alto, CA, USA, 13.02.2011 - 16.02.2011. New York, New York, USA: ACM Press, S. 125.

Fagerlin, Angela; Wang, Catharine; Ubel, Peter A. (2005): Reducing the influence of anecdotal reasoning on people's health care decisions: is a picture worth a thousand statistics? In: *Medical decision making : an international journal of the Society for Medical Decision Making* 25 (4), S. 398–405.

Farjoun, M.; Lai, L. (1997): Similarity Judgements in Strategy formulation: Role, Process and Implications. In: *Strat. Mgmt. J.* 18 (4), S. 255–273.

Faro, David; Rottenstreich, Yuval (2006): Affect, Empathy, and Regressive Mispredictions of Others' Preferences Under Risk. In: *Management Science* 52 (4), S. 529–541.

Fischhoff, Baruch; Slovic, Paul; Lichtenstein, Sarah (1978): Fault trees: Sensitivity of estimated failure probabilities to problem representation. In: *Journal of Experimental Psychology: Human Perception and Performance* 4 (2), S. 330–344.

Forbes, Daniel P. (2005): Are some entrepreneurs more overconfident than others? In: *Journal of Business Venturing* 20 (5), S. 623–640.

Gedikli, Fatih; Jannach, Dietmar; Ge, Mouzhi (2014): How should I explain? A comparison of different explanation types for recommender systems. In: *International Journal of Human-Computer Studies* 72 (4), S. 367–382.

Gettinger, Johannes; Kiesling, Elmar; Stummer, Christian; Vetschera, Rudolf (2013): A comparison of representations for discrete multi-criteria decision problems. In: *Decision Support Systems* 54 (2), S. 976–985.

Giboney, Justin Scott; Brown, Susan A.; Lowry, Paul Benjamin; Nunamaker, Jay F. (2015): User acceptance of knowledge-based system recommendations: Explanations, arguments, and fit. In: *Decision Support Systems* 72, S. 1–10.

Gillenkirch, Robert (2018): Overconfidence. Online verfügbar unter https://wirtschaftslexikon.gabler.de/definition/overconfidence-53937, zuletzt aktualisiert am 19.02.2018.

Giovanni Gavetti & Jan W. Rivkin (2005): How Strategists Really Think: Tapping the Power of Analogy. Hg. v. Harvard Business Review. Online verfügbar unter https://hbr.org/2005/04/how-strategists-really-think-tapping-the-power-of-analogy.

Gkika, Sofia; Lekakos, George (2014 - 2014): Investigating the Effectiveness of Persuasion Strategies on Recommender Systems. In: 2014 9th International Workshop on Semantic and Social Media Adaptation and Personalization. 2014 9th International Workshop on Semantic and Social Media Adaptation and Personalization (SMAP). Corfu, Greece, 06.11.2014 - 07.11.2014: IEEE, S. 94–97.

Golman, Russell; Bhatia, Sudeep (2012): Performance evaluation inflation and compression. In: *Accounting, Organizations and Society* 37 (8), S. 534–543.

Gönül, M. Sinan; Önkal, Dilek; Lawrence, Michael (2006): The effects of structural characteristics of explanations on use of a DSS. In: *Decision Support Systems* 42 (3), S. 1481–1493.

Goodwin, Paul; Sinan Gönül, M.; Önkal, Dilek (2013): Antecedents and effects of trust in forecasting advice. In: *International Journal of Forecasting* 29 (2), S. 354–366.

Gregor; Shirley (2001): Explanations from knowledge-based systems and cooperative problem solving: an empirical study. In: *International Journal of Human-Computer Studies* 54 (1), S. 81–105.

Gregor, S. (1999): Explanations from Intelligent Systems: Theoretical Foundations and Implications for Practice. In: *MIS Quarterly* 23 (4), S. 497.

Grublješič, Tanja; Coelho, Pedro Simoes; Jaklič, Jurij (2019): The Shift to Socio-Organizational Drivers of Business Intelligence and Analytics Acceptance. In: *Journal of Organizational and End User Computing* 31 (2), S. 37–64.

Grublješič, Tanja; Jaklič, Jurij (2015): Business Intelligence Acceptance: The Prominence of Organizational Factors. In: *Information Systems Management* 32 (4), S. 299–315.

Gürdür, Didem; El-khoury, Jad; Törngren, Martin (2019): Digitalizing Swedish industry: What is next? In: *Computers in Industry* 105, S. 153–163.

Hadasch, Frank; Maedche, Alexander; Gregor, S. (2016): The influence of directive explanations on users' business process compliance performance. In: *Business Process Mgmt Journal* 22 (3), S. 458–483.

Haley, Usha C. V.; Stumpf, Stephen A. (1989): Cognitive Trials in Strategic Decision-Making: Linking Theories of Personalities and Cognition. In: *Journal of Management Studies* 26 (5), S. 477–497.

Hamari, Juho; Koivisto, Jonna; Sarsa, Harri (2014): Does Gamification Work? -- A Literature Review of Empirical Studies on Gamification. In: 47th Hawaii International Conference 2014, S. 3025–3034.

Hammond, John S. (2016): Confirmation Bisa: How it affects your organisation and how to overcome it. Hg. v. Harvard Business School. Online verfügbar unter https://online.hbs.edu/blog/post/confirmation-bias-how-it-affects-your-organization-and-how-to-overcome-it.

Han, Yang-Ming; Shen, Chu-San; Farn, Cheng-Kiang (2016): Determinants of continued usage of pervasive business intelligence systems. In: *Information Development* 32 (3), S. 424–439.

Herbert, Theodore T.; Estes, Ralph W. (1977): Improving Executive Decisions by Formalizing Dissent: The Corporate Devil's Advocate. In: *AMR* 2 (4), S. 662–667.

Herlocker, Jonathan L.; Konstan, Joseph A.; Riedl, John (2000): Explaining collaborative filtering recommendations. In: Wendy Kellogg und Steve Whittaker (Hg.): Proceedings of the 2000 ACM conference on Computer supported cooperative work - CSCW '00. the 2000 ACM conference. Philadelphia, Pennsylvania, United States. New York, New York, USA: ACM Press, S. 241–250.

Hoffman, C.; Nathan, B.; Holden, L. (1991): A Comparison of Validation Criteria: Objective versus Subjective Performance Measures and Self- Versus Supervisor Ratings. In: *Personnel Psychology* 44 (3), S. 601–618.

Hoffmann, Arvid O.I.; Post, Thomas (2014): Self-attribution bias in consumer financial decision-making: How investment returns affect individuals' belief in skill. In: *Journal of Behavioral and Experimental Economics* 52, S. 23–28.

Hoffrage, U.; Lindsey, S.; Hertwig, R.; Gigerenzer, G. (2000): Medicine. Communicating statistical information. In: *Science (New York, N.Y.)* 290 (5500), S. 2261–2262.

Hogarth, Robin M.; Makridakis, Spyros (1981): Forecasting and Planning: An Evaluation. In: *Management Science* 27 (2), S. 115–138.

Hosack, Bryan; Hall, Dianne; Paradice, David; Courtney, James (2012): A Look Toward the Future: Decision Support Systems Research is Alive and Well. In: *JAIS* 13 (5), S. 315–340.

Hou, Chung Kuang (2014): Exploring the user acceptance of business intelligence systems in Taiwan's electronics industry: applying the UTAUT model. In: *IJIEM* 8 (3), S. 195.

Hou, Chung-Kuang (2012): Examining the effect of user satisfaction on system usage and individual performance with business intelligence systems: An empirical study of Taiwan's electronics industry. In: *International Journal of Information Management* 32 (6), S. 560–573.

Hou, Chung-Kuang (2016): Understanding business intelligence system continuance intention. In: *Information Development* 32 (5), S. 1359–1371.

Houghton, Susan M.; Simon, Mark; Aquino, Karl; Goldberg, Caren B. (2000): No Safety in Numbers: Persistence of Biases and Their Effects on Team Risk Perception and Team Decision Making. In: *Group & Organization Management* 25 (4), S. 325–353.

Hsee, Christopher K.; Zhang, Jiao; Yu, Fang; Xi, Yiheng (2003): Lay rationalism and inconsistency between predicted experience and decision. In: *J. Behav. Decis. Making* 16 (4), S. 257–272.

Hutchinson, J. Wesley; Alba, Joseph W.; Eisenstein, Eric M. (2010): Heuristics and Biases in Data-Based Decision Making: Effects of Experience, Training, and Graphical Data Displays. In: *Journal of Marketing Research* 47 (4), S. 627–642.

IDC (2017): Data Age 2025: The Evolution of Data to Life-Critical - Don't Focus on Big Data; Focus on the Data That's Big. Online verfügbar unter https://www.seagate.com/files/www-content/our-story/trends/files/Seagate-WP-DataAge2025-March-2017.pdf.

Ireland, R. Duane; Hitt, Michael A.; Bettis, Richard A.; Porras, Deborah Auld de (1987): Strategy formulation processes: Differences in perceptions of strength and weaknesses indicators and environmental uncertainty by managerial level. In: *Strat. Mgmt. J.* 8 (5), S. 469–485.

Ittner, Christopher D.; Larcker, David F.; Meyer, Marshall W. (2003): Subjectivity and the Weighting of Performance Measures: Evidence from a Balanced Scorecard. In: *SSRN Journal*.

Ittner, C. D. and D. F. Larcker (1998): Innovations in performance measurement: Trends and research implications. In: *Journal of Management Accounting Research*, S. 205–238.

Jaklič, Jurij; Grublješič, Tanja; Popovič, Aleš (2018): The role of compatibility in predicting business intelligence and analytics use intentions. In: *International Journal of Information Management* 43, S. 305–318.

Janssen, Marijn; van der Voort, Haiko; Wahyudi, Agung (2017): Factors influencing big data decision-making quality. In: *Journal of Business Research* 70, S. 338–345.

Jensen, Matthew L.; Lowry, Paul Benjamin; Burgoon, Jude K.; Nunamaker, Jay F. (2010): Technology Dominance in Complex Decision Making: The Case of Aided Credibility Assessment. In: *Journal of Management Information Systems* 27 (1), S. 175–202.

John S. Hammond, Ralph L. Keeney, and Howard Raiffa (1998): The Hidden Traps in Decision Making. Hg. v. Harvard Business Review. Online verfügbar unter https://hbr.org/1998/09/the-hidden-traps-in-decision-making-2?registration=success).

Kahneman, Daniel (2012): Thinking, fast and slow. London: Penguin Books.

Kahneman, Daniel; Frederick, Shane (2005): A model of heuristic judgment. In: *The Cambridge hand-book of thinking and reasoning*, S. 267–293.

Kahneman, Daniel; Knetsch, Jack L.; Thaler, Richard H. (1991): Anomalies: The Endowment Effect, Loss Aversion, and Status Quo Bias. In: *Journal of Economic Perspectives* 5 (1), S. 193–206.

Kahneman, Daniel; Tversky, Amos (1972): Subjective probability: A judgment of representativeness. In: *Cognitive Psychology* 3 (3), S. 430–454.

Kaplan, Robert S.; Norton, David (1996): Using the Balanced Scorecard as a Strategic Management System. In: *Harvard Business Review* 74 (1), S. 75–85.

Kaptein, Frank; Broekens, Joost; Hindriks, Koen; Neerincx, Mark: Personalised self-explanation by robots: The role of goals versus beliefs in robot-action explanation for children and adults. In: 26th IEEE International Symposium 28.08.2017 - 01.09.2017, S. 676–682.

Kaufmann, Lutz; Carter, Craig R.; Buhrmann, Christian (2010): Debiasing the supplier selection decision: a taxonomy and conceptualization. In: *Int Jnl Phys Dist & Log Manage* 40 (10), S. 792–821.

Kayande, Ujwal; Bruyn, Arnaud de; Lilien, Gary L.; Rangaswamy, Arvind; van Bruggen, Gerrit H. (2009): How Incorporating Feedback Mechanisms in a DSS Affects DSS Evaluations. In: *Information Systems Research* 20 (4), S. 527–546.

Keil, Mark; Depledge, Gordon; Rai, Arun (2007): Escalation: The Role of Problem Recognition and Cognitive Bias. In: *Decision Sciences* 38 (3), S. 391–421.

Kirs, Peeter J.; Pflughoeft, Kurt; Kroeck, Galen (2001): A process model cognitive biasing effects in information systems development and usage. In: *Information & Management* 38 (3), S. 153–165.

Kohnke, Oliver; Wolf, Tim Robin; Mueller, Karsten (2011): Managing user acceptance: an empirical investigation in the context of business intelligence standard software. In: *IJISCM* 5 (4), S. 269.

Kowalczyk, Martin; Buxmann, Peter (2015): An ambidextrous perspective on business intelligence and analytics support in decision processes: Insights from a multiple case study. In: *Decision Support Systems* 80, S. 1–13.

Kulesza, Todd; Stumpf, Simone; Burnett, Margaret; Yang, Sherry; Kwan, Irwin; Wong, Weng-Keen: Too much, too little, or just right? Ways explanations impact end users' mental models. In: IEEE Symposium on Visual 15.09.2013 - 19.09.2013, S. 3–10.

Kunz, Jennifer (2015): Objectivity and subjectivity in performance evaluation and autonomous motivation: An exploratory study. In: *Management Accounting Research* 27, S. 27–46.

Lai, Vivian; Tan, Chenhao (2019): On Human Predictions with Explanations and Predictions of Machine Learning Models. In: Unknown (Hg.): Proceedings of the Conference on Fairness, Accountability, and Transparency - FAT\* '19. the Conference. Atlanta, GA, USA, 29.01.2019 - 31.01.2019. New York, New York, USA: ACM Press, S. 29–38.

Larrick, Richard P. (2004): Debiasing. In: Derek J. Koehler und Nigel Harvey (Hg.): Blackwell Handbook of Judgment and Decision Making. Malden, MA, USA: Blackwell Publishing Ltd, S. 316–338.

Larrick, Richard P.; Soll, Jack B. (2008): Economics. The MPG illusion. In: *Science (New York, N.Y.)* 320 (5883), S. 1593–1594.

Lee, John D.; See, Katrina A. (2004): Trust in automation: designing for appropriate reliance. In: *Human factors* 46 (1), S. 50–80.

Li, Manning; Gregor, S. (2011): Outcomes of effective explanations: Empowering citizens through online advice. In: *Decision Support Systems* 52 (1), S. 119–132.

Li, Meng (2019): Overconfident Distribution Channels. In: Prod Oper Manag 28 (6), S. 1347–1365.

Li, Susan (2017): Predict Employee Turnover With Python. Online verfügbar unter https://towardsdatascience.com/predict-employee-turnover-with-python-da4975588aa3 .

Lilien, Gary L.; Rangaswamy, Arvind; van Bruggen, Gerrit H.; Starke, Katrin (2004): DSS Effectiveness in Marketing Resource Allocation Decisions: Reality vs. Perception. In: *Information Systems Research* 15 (3), S. 216–235.

Lim, Brian Y.; Dey, Anind K.; Avrahami, Daniel (2009): Why and why not explanations improve the intelligibility of context-aware intelligent systems. In: Dan R. Olsen, Richard B. Arthur, Ken Hinckley, Meredith Ringel Morris, Scott Hudson und Saul Greenberg (Hg.): Proceedings of the 27th international conference on Human factors in computing systems - CHI 09. the SIGCHI Conference. Boston, MA, USA, 04.04.2009 - 09.04.2009. New York, New York, USA: ACM Press, S. 2119.

Limayem, Moez; DeSanctis, Gerardine (2000): Providing Decisional Guidance for Multicriteria Decision Making in Groups. In: *Information Systems Research* 11 (4), S. 386–401.

Loftus, Elizabeth F. (1975): Leading questions and the eyewitness report. In: *Cognitive Psychology* 7 (4), S. 560–572.

Logg, Jennifer M.; Minson, Julia A.; Moore, Don A. (2019): Algorithm appreciation: People prefer algorithmic to human judgment. In: *Organizational Behavior and Human Decision Processes* 151, S. 90–103.

Luft, Joan (2009): Nonfinancial Information and Accounting: A Reconsideration of Benefits and Challenges. In: *Accounting Horizons* 23 (3), S. 307–325.

Mao, Ji; Benbasat, Izak (2001): The effects of contextualized access to knowledge on judgement. In: *International Journal of Human-Computer Studies* 55 (5), S. 787–814.

Martens, David; Provost, Foster (2014): Explaining Data-Driven Document Classifications. In: *MIS Quarterly* 38 (1), S. 73–99.

Merendino, Alessandro; Dibb, Sally; Meadows, Maureen; Quinn, Lee; Wilson, David; Simkin, Lyndon; Canhoto, Ana (2018): Big data, big decisions: The impact of big data on board level decision-making. In: *Journal of Business Research* 93, S. 67–78.

Meyer, Werner G. (2014): The Effect of Optimism Bias on the Decision to Terminate Failing Projects. In: *Project Management Journal* 45 (4), S. 7–20.

Miller, Kent D.; zur Shapira (2004): An empirical test of heuristics and biases affecting real option valuation. In: *Strat. Mgmt. J.* 25 (3), S. 269–284.

Moa, Ji-Ye; Benbasat, Izak (2000): The Use of Explanations in Knowledge-Based Systems: Cognitive Perspectives and a Process-Tracing Analysis. In: *Journal of Management Information Systems* 17 (2), S. 153–179.

Moers, Frank (2005): Discretion and bias in performance evaluation: the impact of diversity and subjectivity. In: *Accounting, Organizations and Society* 30 (1), S. 67–80.

Mowen, Maryanne M.; Mowen, John C. (1986): AN empirical examination of the biasing effects of framing on business decisions. In: *Decision Sciences* 17 (4), S. 596–602.

Musto, Cataldo; Narducci, Fedelucio; Lops, Pasquale; Gemmis, Marco de; Semeraro, Giovanni (2019): Linked open data-based explanations for transparent recommender systems. In: *International Journal of Human-Computer Studies* 121, S. 93–107.

Nah, Fiona; Benbasat, Izak (2004): Knowledge-based Support in a Group Decision Making Context: An Expert-Novice Comparison. In: *JAIS* 5 (3), S. 125–150.

Nakatsu, R. T.; Benbasat, I. (2003): Improving the explanatory power of knowledge-based systems: An investigation content and interface-based enhancements. In: *IEEE Trans. Syst., Man, Cybern. A* 33 (3), S. 344–357.

Namvar, Morteza; Cybulski, Jacob L.; Perera, Luckmika (2016): Using Business Intelligence to Support the Process of Organizational Sensemaking. In: *CAIS* 38, S. 330–352.

Nunes, Ingrid; Taylor, Phillip; Barakat, Lina; Griffiths, Nathan; Miles, Simon (2019): Explaining reputation assessments. In: *International Journal of Human-Computer Studies* 123, S. 1–17.

Önkal, Dilek; Gönül, M. Sinan; Lawrence, Michael (2008): Judgmental Adjustments of Previously Adjusted Forecasts. In: *Decision Sciences* 39 (2), S. 213–238.

Parkes, A. (2012): Persuasive decision support: Improving reliance on decision aids. In: *Pacific Asia Journal of the Association of Information Systems* 4 (3), S. 1–13.

Peters, Ellen; Västfjäll, Daniel; Slovic, Paul; Mertz, C. K.; Mazzocco, Ketti; Dickert, Stephan (2006): Numeracy and decision making. In: *Psychological science* 17 (5), S. 407–413.

Petrushin, Valery A. (1999): Emotion in Speech: Recognition and Application to Call Centers.

Prendergast, Canice; Topel, Robert (1993): Discretion and bias in performance evaluation. In: *European Economic Review* 37 (2-3), S. 355–365.

Pu, Pearl; Li Chen (2007): Trust-inspiring explanation interfaces for recommender systems. In: *Knowledge-Based Systems* 20 (6), S. 542–556.

Puklavec, Borut; Oliveira, Tiago; Popovič, Aleš (2018): Understanding the determinants of business intelligence system adoption stages. In: *IMDS* 118 (1), S. 236–261.

Quijano-Sanchez, Lara; Sauer, Christian; Recio-Garcia, Juan A.; Diaz-Agudo, Belen (2017): Make it personal: A social explanation system applied to group recommendations. In: *Expert Systems with Applications* 76, S. 36–48.

R. Clemen; K. C. Lichtendahl (2002): 2 Debiasing a Single Expert 2. 1 A Judgment Model. In:

Rajan, Madhav V.; Reichelstein, Stefan (2009): Objective versus Subjective Indicators of Managerial Performance. In: *The Accounting Review* 84 (1), S. 209–237.

Ribeiro, Marco Tulio; Singh, Sameer; Guestrin, Carlos: "Why Should I Trust You?". In: Krishnapuram, Shah et al. (Hg.) 2016 – Proceedings of the 22nd ACM, S. 1135–1144.

Richard Ye, L. (1995): The value of explanation in expert systems for auditing: An experimental investigation. In: *Expert Systems with Applications* 9 (4), S. 543–556.

Schulz-Hardt, Stefan; Jochims, Marc; Frey, Dieter (2002): Productive conflict in group decision making: genuine and contrived dissent as strategies to counteract biased information seeking. In: *Organizational Behavior and Human Decision Processes* 88 (2), S. 563–586.

Schwenk, Charles R. (1984): Cognitive simplification processes in strategic decision-making. In: *Strat. Mgmt. J.* 5 (2), S. 111–128.

Schwenk, Charles R. (1985): Management illusions and biases: Their impact on strategic decisions. In: *Long Range Planning* 18 (5), S. 74–80.

Schwenk, Charles R. (1988): THE COGNITIVE PERSPECTIVE ON STRATEGIC DECISION MAKING. In: *Journal of Management Studies* 25 (1), S. 41–55.

Seiter, Mischa (2019): Business Analytics. So nutzen Sie Big Data, Industrie 4.0 und Internet of Things für die Unternehmenssteuerung. 2. Auflage. München: Vahlen Franz.

Shin, Bongsik (2003): An Exploratory Investigation of System Success Factors in Data Warehousing. In: *JAIS* 4 (1), S. 141–170.

Shollo, Arisa; Galliers, Robert D. (2016): Towards an understanding of the role of business intelligence systems in organisational knowing. In: *Info Systems J* 26 (4), S. 339–367.

Sibony, Olivier; Lovallo, Dan; Powell, Thomas C. (2017): Behavioral Strategy and the Strategic Decision Architecture of the Firm. In: *California Management Review* 59 (3), S. 5–21.

Simon, Mark; Houghton, Susan M. (2002): The Relationship among Biases, Misperceptions, and the Introduction of Pioneering Products: Examining Differences in Venture Decision Contexts. In: *Entrepreneurship Theory and Practice* 27 (2), S. 105–124.

Simon, Mark; Houghton, Susan M.; Aquino, Karl (2000): Cognitive biases, risk perception, and venture formation. In: *Journal of Business Venturing* 15 (2), S. 113–134.

Soll, Jack; Milkman, Katherine; Payne, John (2013): A User's Guide to Debiasing.

Staw, Barry M. (1981): The Escalation of Commitment to a Course of Action. In: *The Academy of Management Review* 6 (4), S. 577.

Swartout, William R. (1983): XPLAIN: a system for creating and explaining expert consulting programs. In: *Artificial Intelligence* 21 (3), S. 285–325.

Tan, Wee-Kek; Tan, Chuan-Hoo; Teo, Hock-Hai (2012): Consumer-based decision aid that explains which to buy: Decision confirmation or overconfidence bias? In: *Decision Support Systems* 53 (1), S. 127–141.

Thirathon, U.; Wieder, B.; Ossimitz, M.-L. (2018): Determinants of analytics-based managerial decision-making. In: *International Journal of Information Systems and Project Management* 6 (1), S. 27–40.

Thirathon, Usarat; Wieder, Bernhard; Matolcsy, Zoltan; Ossimitz, Maria-Luise (2017): Big Data, Analytic Culture and Analytic-Based Decision Making Evidence from Australia. In: *Procedia Computer Science* 121, S. 775–783.

Tintarev, Nava; Masthoff, Judith (2012): Evaluating the effectiveness of explanations for recommender systems. In: *User Model User-Adap Inter* 22 (4-5), S. 399–439.

Tsai, Claire I.; Hsee, Christopher K. (2009): A behavioral account of compensation awarding decisions. In: *J. Behav. Decis. Making* 22 (2), S. 138–152.

Tversky, A.; Kahneman, D. (1974): Judgment under Uncertainty: Heuristics and Biases. In: *Science (New York, N.Y.)* 185 (4157), S. 1124–1131.

Tversky, A.; Kahneman, D. (1981): The framing of decisions and the psychology of choice. In: *Science (New York, N.Y.)* 211 (4481), S. 453–458.

Tversky, Amos; Kahneman, Daniel (1973): Availability: A heuristic for judging frequency and probability. In: *Cognitive Psychology* 5 (2), S. 207–232.

van der Stede, Wim A.; Chow, Chee W.; Lin, Thomas W. (2006): Strategy, Choice of Performance Measures, and Performance. In: *Behavioral Research in Accounting* 18 (1), S. 185–205.

Vig, Jesse; Sen, Shilad; Riedl, John (2008): Tagsplanations. In: Cristina Conati, Mathias Bauer, Nuria Oliver und Dan Weld (Hg.): Proceedingsc of the 13th international conference on Intelligent user interfaces - IUI '09. Proceedingsc of the 13th international conference. Sanibel Island, Florida, USA, 08.02.2009 - 11.02.2009. New York, New York, USA: ACM Press, S. 47.

Vigen, Tyler (2020): Spurious corrleations. Online verfügbar unter http://www.tylervigen.com/, zuletzt geprüft am 15.10.2020.

Viscusi, W. Kip; Zeckhauser, Richard J. (2017): Recollection Bias and Its Underpinnings: Lessons from Terrorism Risk Assessments. In: *Risk analysis : an official publication of the Society for Risk Analysis* 37 (5), S. 969–981.

Wang; Benbasat (2009): Interactive Decision Aids for Consumer Decision Making in E-Commerce: The Influence of Perceived Strategy Restrictiveness. In: *MIS Quarterly* 33 (2), S. 293.

Wang, Weiquan; Benbasat, Izak (2007): Recommendation Agents for Electronic Commerce: Effects of Explanation Facilities on Trusting Beliefs. In: *Journal of Management Information Systems* 23 (4), S. 217–246.

Wang, Weiquan; Qiu, Lingyun; Kim, Dongmin; Benbasat, Izak (2016): Effects of rational and social appeals of online recommendation agents on cognition- and affect-based trust. In: *Decision Support Systems* 86, S. 48–60.

Wang, Weiquan; Xu, Jingjun; Wang, May (2018): Effects of Recommendation Neutrality and Sponsorship Disclosure on Trust vs. Distrust in Online Recommendation Agents: Moderating Role of Explanations for Organic Recommendations. In: *Management Science* 64 (11), S. 5198–5219.

Webster, J.; Watson, R. (2002a): Analyzing the past to prepare for the future: Writing a literature review. In: *MIS Quarterly* 26 (2), S. 13–23.

Webster, J.; Watson, R. T. (2002b): Analyzing the past to prepare for the future: Writing a literature review. In: MIS Quarterly, S. xiii–xxiii.

Webster, Jane; Watson, Richard T. (2002c): Analyzing the Past to Prepare for the Future: Writing a Literature Review. In: MIS Quarterly 26 (4), S. xiii–xxiii.

Ye, L. Richard; Johnson, Paul E. (1995): The Impact of Explanation Facilities on User Acceptance of Expert Systems Advice. In: MIS Quarterly 19 (2), S. 157.

Zeni, Thomas A.; Buckley, M. Ronald; Mumford, Michael D.; Griffith, Jennifer A. (2016): Making "sense" of ethical decision making. In: *The Leadership Quarterly* 27 (6), S. 838–855.

Zhang, Jingjing; Curley, Shawn P. (2018): Exploring Explanation Effects on Consumers' Trust in Online Recommender Agents. In: *International Journal of Human—Computer Interaction* 34 (5), S. 421–432.

## 10. Anhang

### Anhang 1: In Interviews ermittelte Einsatzgebiete

Bereich	Anwendung / Einsatzgebiet
Logistik	Software-Anwendung Logistik
	Tourstopzahlen, Tourzeiten, Spritverbrauch, Reifenverschleiß, Reparaturkosten, Gebietskennzahlen,
	Lieferkosten, Budgetplanung, Prozessanalyse, ABC Analyse,
	BA kann in allen Bereichen zur Datenauswertung und anderem genutzt werden! Jeder Teil in einem
	Unternehmen kann mit BA spezifische Auswertungen und Informationen sammeln. In der Logistik: Be-
	wegungsdaten, Kostenentwicklungen, Prozessüberwachung, Fehler etc.
	Wir vertreiben Lagerverwaltungssoftware. Eine ausführliche BA ist in jedem Projekt zwingend erforder-
	lich. Einfach gesagt, geht es um die Intralogistische Materialfluss-Planung.
	Logistik Routen Analyse, Laufwege, Stapler und Routenzug Routen
	Termintreue, Servicelevel, Bestand, Nulldreher, Verschrottungen
	Analyse von fehlerhaften Lieferungen, Verzögerungen etc.  Verzögerungen und Verlust von Sendungen
	Strategische Planung Logistikstrukturen, Standortentscheidungen, Kostenkontrolle und Planung, Qua-
	litätskontrolle
	Logistikcontrolling, Einkaufscontrolling, Kostenanalyse
Produktion	Nachkalkulation
Todaktion	KPI Dashboard in Excel
	Fahrzeugs Daten und Auswertungen: Fahrer Informationen, Lenk- und Ruhe Zeiten und vieles mehr
	Logistik und Produktion ist meist sehr eng verknüpft, auch wird nachgeforscht wieso weshalb und vor
	allem warum
	Qualitätsthemen
	Produktivitäts-, Qualitätsüberwachung etc.
	Analyse von Daten, Q-Kennzahlen (falls das BA ist)
	Produktionscontrolling
Marketing/	Umsatzanalyse, Produktanteile Verkauf, Produktanteile Kunden
Vertrieb	KPI-Dashboard
	Auswertung von Kundendaten
	Gebietsauswertungen, Kundenanalyse, Auftragsbewertung, Upselling, Crossselling, Budgetplanung,
	Prozessanalyse
	Meist nur intern, manchmal hängen aber die logistischen Prozesse oft im Vertrieb fest, bzw. werden
	von dort gesteuert. Dies ist meist kontraproduktiv.
	Analyse von Interviews und Befragungen
	Analytics-Software
	Kundendaten, Cross-selling, up-selling
	Regressionsanalysen zur Erstellung von Kostenmodelle als Basis für die Angebotskalkulation
	Power BI zur Visualisierung der Marketing Budget Planung, Vergleich Abweichung der monatlichen
	Forecasts auf Budget Owner Ebene. Aktuell sind nur Zugänge für das Finance Team und das C-Level
	vorhanden, daher kann das Marketing Team die Vorteile leider nicht nutzen. Sales Daten werden
	ebenfalls auf Power BI zur Verfügung gestellt und visualisiert. Hier sind Zugänge für alle Sales Mana-
	ger vorhanden.
	Campaign success measurements / Evaluations Sales success bis Plan and Yoy Customer retention,
	Cross selling
	Kundenprofilen, was könnte ich dem Kunden A noch anbieten wenn er Produkt X gekauft hat
0	Geschäftsfeldentwicklung
Service	Handy App Fan-Konfigurator
	Reklamtionsanalyse, Anrufauswertung, ID Bewertung, Auftragsabwicklung, Prozessanalyse,
	Ersatzteillogistik siehe oben Logistik.
	Shared Service Center KPI Ermittlung
	Cross-selling, up-selling, maßgeschneiderte Serviceleistungen
Infrastruktur	Volume drivers Efficiency analysis across all functions and levels keine
IIIIIasiiukiui	Reporting-Tool
	Serverauslastung, Datendurchsatz
	Management Reporting und damit verbundenen Analysen
	Reportingsystem für Anlaufprojekte zur standardisierten Kontrolle
	Monitoring-Tool
	Verwendung von Visual Analytics: Simulation von KPIs, Szenarioanalysen, Zeitreihenanalysen, Rolling
	Forecasts - Dash Board mit der Möglichkeit zur unternehmensweiten Erstellung von Ad Hoc Berichten
	auf Grundlage standardisierter Berichte
	Cost drivers
HR	Auslastung
1113	Personnel Expense Monitoring
	keine Angabe
R&D	Projektverfolgung
	i rojomronoigang

	<del>_</del>			
	Wir versuchen immer den Markt zu sondieren, Neue Entwicklungen zu implementieren, neue Techni-			
	ken zu testen, neue Produkte mit einzubinden.			
	Steuerung des R&D Ratios			
	keine Angabe			
Einkauf	Software-Anwendung Einkaufseinsparungen Excel Auswertungen PPV			
	ABC Analyse der Artikel und Bestände, Auswertung der Lieferanten, Bewertung von Lieferkosten,			
	fassungskennzahlen der Mitarbeiter,			
	keine Angabe			
	Einkaufscontrolling			

#### Anhang 2: Fragenbogenstudie: Teil 1 - Zusätzliche Informationen

### Zusätzlich Informationen: Wertschöpfungskette nach Porter

Im Folgenden werden Beispiele für den Einsatz von Business Analytics (BA) entlang der Wertschöpfungskette nach Porter (vgl. Abbildung 1) vorgestellt. Diese Informationen sind für die Beantwortung des Fragebogens nicht zwingend erforderlich, können Ihnen jedoch eine Hilfestellung geben

> Die Abbildung der Wertschöpfungskette nach Porter wurde für diese Veröffentlichung entfernt.

Abbildung 1: Wertschöpfungskette nach Porter

#### Wertschöpfende Aktivitäten

#### Logistik: Transparente Lieferketten

Informationen über Verzögerungen, Liegezeiten und Haftfälle werden zentral erfasst, ausgewertet und Vorhersagen generiert.

#### Produktion: Predictive Maintanance

Durch Analysen der Produktionsdaten können wichtige Ersatzteile mit hohem Verbrauchswert identifiziert werden, um durch Vorhersagen die Stillstandszeiten der Maschinen zu reduzieren. So können automatisch Wartungsaufträge eingeleitet werden.

#### Marketing / Vertrieb: Assoziationsanalyse zur Analyse des Kundenverhaltens

Assoziationsanalyse zur Analyse welche Services oft mit welchen Produkten verkauft werden. Dadurch zukünftig Angebot geeigneter Bundles, um höheren Verkauf zu erzielen.

#### · Service: Identifikation von Einflussfaktoren auf die Kundenzufriedenheit

Mit Hilfe einer Regressionsanalyse wurden verschiedene Attribute auf Eignung als Prädikatoren geprüft; Im Anschluss wurde die Testmenge genutzt um die linearen Gleichungen der Regression zu testen.

#### Unterstützende Aktivitäten

#### Infrastruktur: Forecasting betrieblicher Kennzahlen wie Umsatz und Absatz

Vorhersage betrieblicher Kennzahlen unter Berücksichtigung einer Vielzahl von Faktoren, die aus einer Vielzahl von Daten abgeleitet werden.

#### Human Ressource: Auswertung von Bewerbungen

Mittels Text Mining können Bewerbungen dahingehend untersucht werden, welche Anforderungen Bewerber mitbringen und in ihrer Bewerbung ansprechen. So können aus einer Vielzahl von Bewerbungen weniger Geeignete identifiziert werden.

#### Research & Development: Analyse Patentanmeldungen:

Durch Text Mining können Anmeldungen beim Patentamt nach der Häufigkeit auftretender Worte untersucht werden. So können Schlagworte identifiziert werden, die einen aktuellen Trend von Entwicklungen offenbaren. So kann der technologische Aufschluss oder der Spitzenerhalt gewährt bzw. gesichert werden.

#### Einkauf: Automatisierte Einpreisung von Rohstoffeffekten im Einkauf

Basierend auf den Vertragsdaten, aktuellen Rohstoffpreisen und Preisaktualisierungsmechanismen aktualisiert die SaaS die Preise automatisch und identifiziert mittels Ausreißeranalyse Stücke mit Optimierungspotential.

# Anhang 3: Qualitative Abfrage des Grundes für den geringen Einsatz von BA bzw. konkrete Anwendungsfälle von BA

Bereich	Grund
Logistik	Haben die Logistik ausgelagert
•	Einfache Abläufe, Wiederkehrende Abläufe
	IT Tools veraltet. Somit wäre ein hoher manueller Aufwand notwendig
	Fehlende Software, Freigabe, Kosten
Produktion	Wir sind Handelsunternehmen
	Anwendung nicht so intuitiv logisch wie in der Logistik. Ausnahme: Instandhaltung . Auch hier wird mit-
	tels Sensoren BA angewendet
	Zu wenig Anwendungsfälle und Priorisierung der Ressourcen in ausgewählte Funktionsbereiche
	Zu geringe Bedeutung. Handelsunternehmen mit vereinzelter Produktionstätigkeit.
Marketing /Ver-	Zu kleiner Bereich
trieb	Noch nicht umgesetzt
	Zu klein, deshalb nur Excel Dateien
	Annahme, fehlende Expertise.
Service	Zu kleiner Bereich
	Wenig Expertise in der Führungsebene
	Servicetechniker fahren zu Kunden und beheben das Problem, d. h. keine Möglichkeiten
	Bei Service geht es um manuelle Aufträge (z. B. Wartung), kein Use Case
Infrastruktur	Zu klein, Kosten zu hoch.
	Wird nicht der richtige Fokus drauf gelegt, und es fehlt an Struktur
HR	Wie sind 12 Personen. Alle kennen sich persönlich und Probleme oder unzulässige Bedingungen wer-
	den besprochen und behoben.
	HR BA könnte in meiner Welt deutlich besser sein, wenn wir hier gerade mal der Lohn und die Kran-
	kentage bewertet, aber die Leistung der Mitarbeiter wird nicht transparent bewertet, und dokumentiert.
	Hier gibt es noch einiges zu verbessern. Auch wenn wir Mitarbeiterbefragungen durchführen und mitt-
	lerweile auch schon entwickeln, dennoch ist noch sehr viel Potenzial nach oben.
	Von automatischer Auswertung von Lebensläufen oder Ähnlichem halten wir nichts
	Sehr schwierig, wegen Datenschutz in der HR Daten zu erheben und auszuwerten
R&D	Kleine Firma, 5 Mitarbeiter damit wenig anfallende Daten
	Macht keinen Sinn in der Hardwareentwicklung
	Wir konstruieren Komponenten und haben keinen Bedarf
	Ich vermute, dass zu wenige Daten zur Analyse anfallen.
Einkauf	Viel zu klein
	Noch nicht umgesetzt
	Hier kommen nur selten Projekte rein. Wenn dann muss auch hier eine BA geschrieben werden. Geht
	dann meist in Richtung Absatzprognosen etc.

## Anhang 4: Qualitative Antworten bzgl. der Frage, warum Erkenntnisse aus BA nicht akzeptiert werden

Bereich	Grund		
Produktion	Erfahrung wird höher gewichtet		
Marketing	Der Vertrieb ist oft der Heilige Gral der Unternehmen, wenn wir mit dem LVS die dortigen Abläufe än-		
	dern wollen, haben wir es enorm schwer. Bzw. Die GF sagt, im Vertrieb darf nichts geändert werden,		
	der sei zu wichtig.		
Service	Wegen wenig Expertise und weichen Faktoren		
	Da die Daten unsicher sind, weder Telefonanlage noch Datenbasis sind korrekt		
	Gibt kaum Anwendungsfälle		
	Kein Use Case vorhanden		
Infrastruktur	Da sich nur sporadisch jemand abgestellt wird, und keine klare Kompetenz da ist, wird oft alles in		
	Frage gestellt.		
HR	Nasenfaktoren und persönliche Netzwerke		
	Alte Strukturen		
	HR Themen sind meistens persönlich und kaum mit Analytics zu lösen.		
	Wenige Berührungspunkte. Viel Abstimmungsbedarf mit dem Betriebsrat		
R&D	Veraltete Strukturen		
	Gibt kaum Anwendungsfälle		
Einkauf	Altmodische Prozesse, fehlender Drang der Führungsebene zur Durchsetzung von BA Tools. Altes		
	Mindset der Führungskräfte		

#### Anhang 5: Interviewleitfaden

- 1. Einstieg
  - a. Vorstellung Interviewer
  - b. Forschungsarbeit vorstellen
  - c. Konkrete Zielsetzung des Interviews erklären: Erfahrungen aus Gesprächen mit Kunden, Probleme Ihrer Kunden mit dem Produkt, Mögliche Akzeptanzfaktoren
  - d. Vorstellung des Interviewee
    - i. Rolle des Interviewees im Unternehmen?
- 2. Hauptteil
  - a. Produkt
    - i. Wer sind die Kunden?
    - ii. Wo sitzen die Kunden?
    - Auf welche Entscheidungen zielt das Produkt ab? Strategisch/Operativ/Taktisch
    - iv. In welchen Bereichen/Branchen wird das Produkt eingesetzt?
  - b. Nutzung
    - i. Wie kann man sich den typischen Endnutzer vorstellen? Wichtig: Nicht Kunde sondern Nutzer oder: Kunde gleich Nutzer?
    - ii. Kommunikation mit dem Kunden in welchem Turnus?
    - iii. Können Sie den Nutzungsgrad überprüfen?
    - iv. Wie wird das Produkt dem Kunden nähergebracht? z.B. durch Trainings
    - v. Feedback des Kunden über das Produkt?
    - vi. Wie können Sie sich erklären, dass ein Produkt nicht vollumfänglich für Entscheidungen genutzt werden?
    - vii. Gibt es Unterschiede zwischen Kunden aus dem Mittelstand und großen Konzernen?
  - c. Perfekte Welt: Wo sehen Sie persönlich Verbesserungspotenzial, damit das Produkt noch zielführender genutzt wird? (eigenes UN, Kunden-UN, Nutzer)
- 3. Schluss
  - a. Bitte Formular unterzeichnen und zurückschicken
  - b. Möchten Sie über weiteren Verlauf des Projekts informiert werden? In Verteiler aufnehmen

#### **Anhang AP4**

#### Anhang 6: Detaillierte Informationen zur systematischen Literaturrecherche

Einschlusskriterium und Ausschlusskriterien

Kriterium	Beschreibung
Einschlusskriterium (EK)	Der Artikel umfasst mindestens eine Erklärungsmethode aus dem Bereich Information Systems.
Ausschlusskriterien 1 (AK1)	Artikel ist nicht in Englisch verfasst.
Ausschlusskriterien 2 (AK2)	Artikel liegt den Fokus nicht auf Erklärungsmethoden.
Ausschlusskriterien 3 (AK3)	Artikel beschreibt die verwendeten Erklärungsmethoden nicht.
Ausschlusskriterien 4 (AK4)	Artikel prüft den Einfluss auf den Nutzer nicht empirisch.

Anzahl Artikel bei den entsprechenden Suchschritten

Suchschritt	Anzahl an Paper bzw. Aufsätze		
	Scopus	IEEE	
Anfängliche Suchergebnisse	194	436	
EK	85	66	
Ausschlusskriterien			

AK1	0	3
AK2	18	4
AK3	2	0
AK4	44	55
Verbleibende Literatur nach Ausschluss	21	4
Gesamtzahl, der durch die Datenbanksuche gefundenen Artikel	25	
Rückwärtssuche	5	
Vorwärtssuche	14	
Gesamtzahl, der in der Analyse verwendeten Paper bzw. Artikel	44	

Anhang 7: Erklärungsmethoden - Bezeichnungen, Alternativbezeichnungen und Verwendungszweck

Erklärungsmethode	Alternative Bezeichnung	Erwähnt in
Justification	- Type II - Support - Deep - Why	Ye und Johnson (1995); Richard Ye (1995); Moa und Benbasat (2000); Limayem und DeSanctis (2000); Mao und Benbasat (2001); Nakatsu und Benbasat (2003); Arnold et al. (2004); Gönül et al. (2006); Arnold et al. (2006); Wang und Benbasat (2007); Önkal et al. (2008); Cramer et al. (2008); Wang und Benbasat (2009); Lim et al. (2009); Jensen et al. (2010); Li und Gregor (2011); Tan et al. (2012); Goodwin et al. (2013); Giboney et al. (2015); Wang et al. (2016); Wang et al. (2018)
Rule Trace	<ul><li>Type I</li><li>Line of Reasoning</li><li>How</li><li>Why</li><li>Belief-based</li></ul>	Ye und Johnson (1995); Richard Ye (1995); Moa und Benbasat (2000); Mao und Benbasat (2001); Nakatsu und Benbasat (2003); Arnold et al. (2004); Arnold et al. (2006); Wang und Benbasat (2007); Wang und Benbasat (2009); Jensen et al. (2010); Ehrlich et al. (2011); Tan et al. (2012); Bussone et al. (2015); Wang et al. (2016); Kaptein et al. ; Wang et al. (2018)
Strategic	<ul><li>Type III</li><li>Control</li><li>Goal-based</li></ul>	Ye und Johnson (1995); Richard Ye (1995); Moa und Benbasat (2000); Arnold et al. (2004); Arnold et al. (2006); Wang und Benbasat (2009); Tan et al. (2012); Wang et al. (2016); Kaptein et al.
Tradeoff	- Guidance	Pu und Li Chen (2007); Wang und Benbasat (2007); Chen und Wang ; Wang et al. (2018); Nunes et al. (2019)
Neighbor Style		Herlocker et al. (2000); Bilgic und Mooney (2005b); Kulesza et al. ; Gedikli et al. (2014); Coba et al. (2018 - 2018)
Definition	<ul><li>Type IV</li><li>Declarative</li><li>Background</li></ul>	Gregor und Shirley (2001); Arnold et al. (2004); Arnold et al. (2006); Jensen et al. (2010)
Confidence		Herlocker et al. (2000); Gedikli et al. (2014); Bussone et al. (2015)
Social		Gkika und Lekakos (2014 - 2014); Quijano-Sanchez et al. (2017); Coba et al. (2018 - 2018)
Feature		Tintarev und Masthoff (2012); Chang et al. ; Coba et al. (2018 - 2018); Musto et al. (2019)
Tag	- Keyword	Bilgic und Mooney (2005b); Vig et al. (2008); Gedikli et al. (2014)
Influence	- Feature	Bilgic und Mooney (2005b); Lai und Tan (2019); Ribeiro et al.
Algorithm		Kulesza et al.

Erklärungsmethode	Alternative Bezeichnung	Erwähnt in
Procedural		Gregor und Shirley (2001); Zhang und Curley (2018)
FAQ		Berry et al. (1995)
Directive		Hadasch et al. (2016)
Example		Lai und Tan (2019)
"Why not"		Lim et al. (2009)
"How to"		Lim et al. (2009)
"What if"		Lim et al. (2009)

Anhang 8: Erklärungsmethoden und dessen Einfluss auf die Nutzer des Systems

Positiver Effekt auf	Shown by
die Akzeptanz der Ergebnisse des Systems & die Wahrnehmung des Systems	Richard Ye (1995), Ye und Johnson (1995), Cramer et al. (2008), Tan et al. (2012), Mao und Benbasat (2001), Önkal et al. (2008), Limayem und DeSanctis (2000)
die Verständlichkeit des Systems	Cramer et al. (2008), Lim et al. (2009), Li und Gregor (2011), Moa und Benbasat (2000), Limayem und DeSanctis (2000), Wang und Benbasat (2009), Nakatsu und Benbasat (2003)
das Vertrauen in das System	Wang und Benbasat (2007), Cramer et al. (2008), Goodwin et al. (2013), Wang et al. (2016), Wang et al. (2018), Musto et al. (2019)
Problemlösungsfähigkeit	Gregor und Shirley (2001), Nakatsu und Benbasat (2003)
die wahrgenommene Entscheidungsqualität & Zufriedenheit	Li und Gregor (2011), Limayem und DeSanctis (2000)
die Akzeptanz der Ergebnisse des Systems & Wahrnehmung des Sys- tems	Richard Ye (1995), Ye und Johnson (1995), Arnold et al. (2006), Wang und Benbasat (2007), Tan et al. (2012)
die Verständlichkeit des Systems	Wang und Benbasat (2009)
das Vertrauen in das System	Wang und Benbasat (2007), Wang et al. (2016), Wang et al. (2018)
Problemlösungsfähigkeit	Ehrlich et al. (2011), Bussone et al. (2015)
die Akzeptanz der Ergebnisse des Systems & Wahrnehmung des Sys- tems	Richard Ye (1995), Ye und Johnson (1995), Arnold et al. (2006), Tan et al. (2012)
die Verständlichkeit des Systems	Wang und Benbasat (2009)
die Akzeptanz der Ergebnisse des Systems & Wahrnehmung des Sys- tems	Chen und Wang , Nunes et al. (2019)
	die Akzeptanz der Ergebnisse des Systems & die Wahrnehmung des Systems  die Verständlichkeit des Systems  das Vertrauen in das System  Problemlösungsfähigkeit  die wahrgenommene Entscheidungsqualität & Zufriedenheit  die Akzeptanz der Ergebnisse des Systems & Wahrnehmung des Systems  die Verständlichkeit des Systems  das Vertrauen in das System  Problemlösungsfähigkeit  die Akzeptanz der Ergebnisse des Systems & Wahrnehmung des Systems  die Verständlichkeit des Systems  die Verständlichkeit des Systems  die Verständlichkeit des Systems

Explanation Method	Positiver Effekt auf	Shown by
	das Vertrauen in das System	Wang und Benbasat (2007), Wang et al. (2016), Chen und Wang , Wang et al. (2018)
	die wahrgenommene Entscheidungsqualität & Zufriedenheit	Chen und Wang , Nunes et al. (2019)
Neighbor Style	Akzeptanz der Ergebnisse des Systems & Wahrnehmung des Systems	Herlocker et al. (2000), Coba et al. (2018 - 2018)
	Verständlichkeit des Systems	Kulesza et al.
	das Vertrauen in das System	Kulesza et al.
Definition	Akzeptanz der Ergebnisse des Systems & Wahrnehmung des Systems	Jensen et al. (2010)
	Problemlösungsfähigkeit	Gregor und Shirley (2001)
Confidence	Verständlichkeit des Systems	Kulesza et al.
	Problemlösungsfähigkeit	Lai und Tan (2019)
Social	Akzeptanz der Ergebnisse des Systems	Quijano-Sanchez et al. (2017)
	Vertrauen in das System	Quijano-Sanchez et al. (2017)
	wahrgenommene Qualität der Ent- scheidung sowie Zufriedenheit mit der Entscheidung	Quijano-Sanchez et al. (2017)
Feature	Akzeptanz der Ergebnisse des Systems	Coba et al. (2018 - 2018)
	Vertrauen in das System	Chang et al.; Musto et al. (2019)
	Problemlösungsfähigkeit	Tintarev und Masthoff (2012)
	wahrgenommene Qualität der Ent- scheidung sowie Zufriedenheit mit der Entscheidung	Tintarev und Masthoff (2012), Chang et al.
Tag	Verständlichkeit des Systems	Vig et al. (2008)
	Problemlösungsfähigkeit	Bilgic und Mooney (2005b), Gedikli et al. (2014)
	wahrgenommene Qualität der Ent- scheidung sowie Zufriedenheit mit der Entscheidung	Vig et al. (2008), Gedikli et al. (2014)
Influence	Das Vertrauen in das System	Lai und Tan (2019)
	Problemlösungsfähigkeit	Lai und Tan (2019)
	Verständlichkeit des Systems	Ribeiro et al.
	wahrgenommene Qualität der Ent- scheidung sowie Zufriedenheit mit der Entscheidung	Bilgic und Mooney (2005b)
Algorithm	das Vertrauen in das System	Kulesza et al.
	Verständlichkeit des Systems	Kulesza et al.

Explanation Method	Positiver Effekt auf	Shown by
Procedural	Problemlösungsfähigkeit	Gregor und Shirley (2001)
Directive	Problemlösungsfähigkeit	Hadasch et al. (2016)
"Why not"	Verständlichkeit des Systems	Lim et al. (2009)

#### Anhang 9: Beschreibung der weiteren Erklärungsmethoden

Tradeoff-Erklärungen geben einen objektiven Überblick über mögliche Einschränkungen der Ergebnisse des Systems und werden verwendet, um Vergleiche zwischen den Empfehlungen des Systems und anderen möglichen Schlussfolgerungen zu geben (Wang & Benbasat, 2007). In ihrer Studie von 2007 zeigten Wang und Benbasat Tradeoff-Erklärungen, während das System den Benutzer nach seinen Präferenzen fragte. In diesem Fall erläuterten die Erklärungen, wie eine bestimmte Präferenz des Benutzers die möglichen Ergebnisse einschränken kann. Alle Erklärungen sind in Textform und in natürlicher Sprache verfasst und müssen vom Benutzer angefordert werden, um darauf zuzugreifen. Sonderfälle stellen die Empfehlungssysteme von Nunes et al. (2019) sowie von L. Chen und Wang (2017) und Pu und Chen (2007) dar. Nunes et al. (2019) stellten in einer Tabelle Eigenschaften von Dienstleistungsanbietern vor, die zusätzlich zu den textuellen Erläuterungen zum Vergleich herangezogen wurden. Die Teilnehmer ihrer Studie zogen es vor, die Ergebnisse zu analysieren, anstatt ganze Sätze zu lesen. Pu und Chen (2007) und kürzlich auch L. Chen und Wang (2017) verwendeten Kurzfassungen der Tradeoff-Erklärungen als Überschriften für empfohlene Produktkategorien. Das Empfehlungssystem von Pu und Chen (2007) beispielsweise empfahl nicht nur einen Laptop, sondern führte weitere Laptops unter einer Kategorie mit der Aufschrift "Wir empfehlen auch die folgenden Produkte, weil sie billiger und leichter sind, aber eine geringere Prozessorgeschwindigkeit haben" (S. 551) und anderen ähnlichen Kategorien auf.

Erklärungen im **Neighbor** Stil basieren auf dem Verhalten oder auf den Präferenzen von Benutzern, die den Benutzern eines Systems ähneln (Herlocker, Konstan, & Riedl, 2000). Das Verhalten der Nachbarn kann z.B. frühere Käufe (Gedikli, Jannach, & Ge, 2014) oder das Hören bestimmter Lieder (Kulesza et al., 2013) umfassen. Die Präferenzen der Nachbarn sind oft Bewertungen von gekauften Produkten oder konsumierten Unterhaltungsmedien (Gedikli et al., 2014). In allen analysierten Beiträgen wurden Erklärungen im Nachbarschaftsstil im Zusammenhang mit Empfehlungssystemen für Filme oder Musik verwendet. Die Erklärungen wurden automatisch neben den Empfehlungen bereitgestellt. Herlocker et al. (2000) testen 21 verschiedene Erklärungsmethoden, die für Empfehlungssysteme verwendet werden können, wobei mehrere auf dem Nachbarschaftsstil<sup>2</sup> basierten. Drei davon werden im Detail beschrieben. Die erste Erklärung gibt die Anzahl der Nachbarn für jede mögliche Sternenbewertung an.

<sup>&</sup>lt;sup>2</sup> While 21 explanation methods are tested and named, only four are described in detail. Unfortunately, the hyperlink referring to the missing 17 explanations is not working anymore. Therefore, this paper only considers the four explanation methods (of which three were Neighbor Style explanations) described in detail.

Die zweite Erklärung zeigt ein Histogramm, in dem die Anzahl der Bewertungen durch Nachbarn in Gruppen von "guten" und "schlechten" Bewertungen zusammengefasst sind (S.247), das auch von Bilgic und Mooney (2005) verwendet wurde. Das letzte ist ein Balkendiagramm, wobei jeder Balken die Bewertung eines Nachbarn darstellt. Die Ähnlichkeit jedes Nachbarn wird auf der x-Achse angezeigt, wobei die Ähnlichkeit mit höheren x-Werten abnimmt. Gedikli et al. (2014) testen zusätzlich ein Tortendiagramm, das den prozentualen Anteil der Sternebewertungen durch die Nachbarn sowie ein Histogram anzeigt, das mit Ausnahme des zweiten Beispiels von Herlocker et al. (2000) die Bewertungen nicht gruppierte. Kulesza et al. (2013) listen die Namen der Künstler in einer Tabelle, die von den Nachbarn eines Benutzers angehört wurden, neben einem Text auf, der erklärt, was in dieser Tabelle angezeigt wird.

Definitionen oder terminologische Erklärungen enthalten Definitionen oder Erklärungen, um das Ergebnis zu verbessern und mehr Hintergrundinformationen zu geben (Gregor & Benbasat, 1999). Darüber hinaus besteht eine ihrer Aufgaben darin, die Bedeutung der zugrunde liegenden Wissensteile zu erklären, auf denen das System aufgebaut wurde (Swartout & Smoliar, 1987). Definitionserklärungen wurden in vier verschiedenen Arbeiten verwendet, die alle in Verbindung mit KBS (Arnold et al., 2006; Gregor, 2001) oder DSS (Arnold et al., 2004, 2006; Jensen et al., 2010) für Finanzanalysen verwendet wurden. Die Erläuterungen wurden nach Aufruf durch den Benutzer gegeben, z.B. durch Klicken auf bestimmte Wörter, für die der Benutzer weitere terminologische Kenntnisse benötigte (Arnold et al., 2004, 2006) oder auf einen Button mit der Beschriftung "Explanation" (Gregor, 2001) oder "Define" (Jensen et al., 2010, S. 189). Auch alle Erklärungen wurden in natürlicher Sprache verfasst und dienten sowohl zur Erläuterung des Inputs als auch des Outputs.

Confidence Erklärungen geben die Zuversicht des Systems in seine Ergebnisse oder Empfehlungen an (Bussone et al., 2015). Während normalerweise die Zuversicht des Systems in die von ihm abgegebenen Empfehlungen zum Ausdruck kommt (Bussone et al., 2015), kann diese Zuversicht weiter ausgedrückt werden, indem das System sich bei seiner Argumentation auf seine bisherige Leistung bei Empfehlungen für Benutzer stützt. Zum Beispiel, indem gesagt wird: "[Das System] hat für Sie in der Vergangenheit 80% der Zeit korrekt vorhergesagt" (Herlocker et al., 2000, S. 247). Die meisten Confidence-Erklärungen finden sich in Arbeiten, welche diese Erklärungen im Zusammenhang mit Empfehlungssystemen verwendeten (Gedikli et al., 2014; Herlocker et al., 2000; Kulesza et al., 2013). Weitere Anwendungsbereiche sind die klinische Diagnose (Bussone et al., 2015) und die Klassifizierung möglicher Täuschung in Hotelbewertungen (Lai & Tan, 2019). Herlocker et al. (2000) stellten die Zuversicht eines Empfehlenden als ein Sterne-Ratingintervall von 1 bis 5 Sternen neben der vorhergesagten Nutzerbewertung dar. Eine Methode, die später von Gedikli et al. (2014) angewandt wurde. Eine schriftliche Beschreibung der Zuversicht wird von Kulesza et al. (2013) zusätzlich zu einem Tortendiagramm verwendet, in dem der Vertrauensteil durch grüne Farbe dargestellt wird. Bussone et al. (2015) und Lai und Tan (2019) zeigen die Zuversicht als prozentuale Bewertung an.

Soziale Erklärungen erläutern das Ergebnis, indem sie die Empfehlung mit sozialen Faktoren in Zusammenhang mit Gruppenmitgliedern (Quijano-Sanchez, Sauer, Recio-Garcia, & Diaz-Agudo, 2017) oder mit Präferenzen von Freunden (Coba, Zanker, Rook, & Symeoni-dis, 2018) begründen. Zu den sozialen Faktoren gehören die Persönlichkeit des Benutzers (Durchsetzungsvermögen, zurückhaltend oder kooperativ), die Stärke der Bindung (beschreibt die Nähe zu anderen Benutzern in der Gruppe oder zu Freunden) und die Zufriedenheit mit früheren Gruppenentscheidungen (Quijano-Sanchez et al., 2017). Soziales kann auch als ein Untertyp der Neighbor Stil Erklärungen angesehen werden. Mit dem Unterschied, dass der Nutzer die Nachbarn persönlich kennt (Coba et al., 2018). In drei Aufsätzen der Analyse wurden soziale Erklärungen verwendet, die alle die Ergebnisse von Empfehlungssystemen für Filme erläutern und diese Erklärungen automatisch zusammen mit dem empfohlenen Film liefern. Coba et al. (2018) verwendeten in ihrer Erklärung die Facebook-Freunde eines Benutzers, indem sie schriftlich darauf hinwiesen, wie einige von ihnen den empfohlenen Film bewerteten. Gkika und Lekakos (2014) verwendeten ebenfalls Facebook-Freunde, anstatt die Bewertung anzuzeigen, gaben sie nur die Information an, dass ein Freund den Film empfohlen hat oder ihm gefällt. Quijano-Sanchez et al. (2017) benutzten die drei oben aufgezählten sozialen Faktoren, um eine schriftliche Erklärung zu verfassen, um die Entscheidungsfindung in Gruppen zu unterstützen. Ein Beispiel, das auf der Stärke der Bindung zwischen dem Benutzer und seinem Freund basiert, könnte die folgende Erklärung sein: "Obwohl wir vorausgesagt haben, dass Ihre Präferenz für diesen speziellen Punkt nicht sehr hoch ist, hält Ihr Freund V, dem Sie sehr vertrauen, dies für eine sehr gute Option" (Quijano-Sanchez et al., 2017, S. 43). Darüber hinaus entwickelten dieselben Autoren eine grafische Form der sozialen Erklärung, bei der die Dicke einer Grafik zwischen einem Benutzer und seinem Freund die Stärke der Bindung darstellt, die Größe des Facebook-Profilbildes des Benutzers oder Freundes den persönlichen Faktor zeigt und ein Emoticon die Zufriedenheit jedes Freundes mit früheren Gruppenentscheidungen anzeigt.

Feature-Erklärungen basieren auf Merkmalen eines empfohlenen Objekts, welcher z.B. der Preis, die Anzeigegröße einer Kamera oder das Genre eines Films sein können (Tintarev & Masthoff, 2012). Meistens beschreiben Feature-Erklärungen nur wenige von insgesamt allen Merkmalen eines Objekts, da eine große Anzahl von Merkmalen mögliche Platzbeschränkungen überschreiten, die Lesezeit der Erklärungen verlängern und damit die Effizienz der Entscheidungsfindung des Benutzers verringern würde (Tintarev & Masthoff, 2012). In vier Aufsätzen dieser Analyse wurden Feature-Erklärungen verwendet, die alle die Empfehlungen von Empfehlungssystemen unterstützen. Coba et al. (2018) zeigten neben dem empfohlenen Film auch die Bewertungen ähnlicher Filme, die der Benutzer bereits gesehen hat. Ähnliche Filme wurden auf der Grundlage ihres Genres ausgewählt. Tintarev und Masthoff (2012) verglichen eine personalisierte Version von Feature-Erklärungen mit einer nicht personalisierten Version. Während die nicht personalisierte Erklärung nur die Merkmale des empfohlenen Artikels beschreibt, vergleicht die personalisierte Version diese Merkmale mit den angegebenen Präferenzen des Benutzers. Anhang 2 zeigt ein Beispiel für eine personalisierte Feature-Erklärung. Chang, Har-per und Terveen (2016) ließen Crowdworker

Erklärungen für ihr Empfehlungssystem schreiben, die auf Merkmalen von Filmen, zum Beispiel dem Genre, basieren. Schließlich erläuterten Musto, Narducci, Lops, Gemmis und Semeraro (2019) die Empfehlung, indem sie den empfohlenen Artikel mit einem anderen Artikel mit den gleichen Merkmalen abglichen, der dem Benutzer zuvor gefiel. Die Links waren entweder direkt, z.B. beide Bücher hatten den gleichen Autor, oder indirekt, z.B. die Autoren beider Bücher hatten die gleiche Nationalität. Alle Wissenschaftler lieferten die Erläuterungen unmittelbar zusammen mit der Empfehlung.

Die Tag-Erklärungen basieren auf einem oder mehreren Tags, die sich auf einen Artikel beziehen. Diese Tags bestehen meist aus einem Wort und "beschreiben, was ein Gegenstand ist, worum es geht oder welche Eigenschaften er hat" (Vig, Sen, & Riedl, 2008, S. 48). Jeder Gegenstand kann durch die Verwendung dieser Tags beschrieben oder charakterisiert werden (Gedikli et al., 2014). Tag-Erklärungen werden verwendet, um Empfehlungen von Filmen (Gedikli et al., 2014; Vig et al., 2008) oder Büchern zu erläutern und werden automatisch mit der Empfehlung versehen. Es gibt verschiedene Möglichkeiten, Tag-Erklärungen zu präsentieren. Vig et al. (2008) z.B. führen Tags zusammen mit der berechneten Relevanz oder der Präferenz des Benutzers für diese Tags auf. Die Relevanz wird durch einen Balken dargestellt, die Präferenz durch eine Sternenbewertung, wobei beide auf der Grundlage der früheren Bewertungen verschiedener Filme durch den Benutzer berechnet werden. Die Erklärungen enthalten entweder nur die Präferenz, nur die Relevanz oder beides, und die Tags sind entweder nach Referenz oder nach Relevanz sortiert. Gedikli et al. (2014) präsentierten die Tag-Erklärung als Tag-Wolke. Eine Tag-Wolke ist ein Bereich, in dem alle mit einem Artikel verbundenen Tags aufgelistet sind, jedoch unsortiert und in verschiedenen Größen. Die Größe eines Tags repräsentiert die Anzahl der Male, die dieser Tag zu diesem Artikel gegeben wurde. Darüber hinaus kann eine Tagcloud personalisiert werden, indem man die Tags entsprechend den Präferenzen des Benutzers einfärbt. Während blaue Tags bevorzugt werden, sind rote Tags beim Benutzer unbeliebt. Schließlich haben Bilgic und Mooney (2005) eine Tabelle mit den Tags eines Buches erstellt, in der die Anzahl der Tags angezeigt wird, die diesem Artikel zugeordnet wurden, sowie die Relevanz dieses Tags für den Benutzer.

Die folgenden Erklärungsmethoden fanden sich nur in ein oder zwei Arbeiten und konnten mit den zuvor erläuterten Erklärungsmethoden nicht kategorisiert werden. Procedural bzw. Verfahrenserklärungen stellen eine Kombination aus Justification und Rule Trace Erklärungen dar, die zur Erklärung des Outputs eines KBS (Gregor, 2001) oder eines Empfehlungssystems (Zhang & Curley, 2018) verwendet werden. Berry, Gillie und Banbury (1995) schufen Erklärungen für ihre KBS für Arzneimittelverschreibungen auf der Grundlage häufig gestellter Fragen von Patienten, so genannte FAQ-Erklärungen. Directive bzw. Richtlinienerklärungen beschreiben, wie ein Konsument eine bestimmte Tätigkeit ausüben sollte (Hadasch, Maedche, & Gregor, 2016). Diese Erklärungen wurden zusätzlich zur schriftlichen Beschreibung in Textform oder mit einem kommentierten Prozessablaufdiagramm dargestellt. Darüber hinaus wurden die Erklärungen intelligent dargestellt, und zwar genau dann, wenn der Benutzer im

Begriff war, eine Aufgabe auszuführen, die nicht dem vorgegebenen Prozess entsprach. Neben Erklärungen zum Einfluss führten Lai und Tan (2019) Beispielhafte Erklärungen ein. Durch das Aufzeigen von Beispielen, die dem erklärten, klassifizierten Gegenstand und der Klassifikation des Systems ähnlich sind, versuchten sie, dem Benutzer das nicht abgeleitete Klassifikationsmodell zu erläutern. Die letzten drei Erklärungen, die im Laufe der Literaturanalyse gefunden wurden, wurden alle von Lim et al. (2009) vorgestellt, die verschiedenen Methoden untersuchten, um den Teilnehmern ihrer Studie ein zugrunde liegendes Entscheidungsbaummodell zu erklären. Die "Why not" Erklärungen verdeutlichen, warum etwas nicht in einer bestimmten Weise empfohlen oder klassifiziert wird. "How to" Erklärungen zeigen, welche Eingabewerte erforderlich sind, um bestimmte Ausgabewerte zu erreichen. Schließlich führen "What if" Erklärungen die Eingaben des Benutzers durch das Modell und liefern das mögliche Ergebnis, ohne das Modell auf die Daten anzuwenden.

Diese Literaturanalyse erbrachte 19 verschiedene Erklärungsmethoden. Während einige von ihnen umfassend erforscht wurden, z.B. Justification, Rule Trace oder strategische Erklärungen, sind andere relativ neu, z.B. Influence- oder Algorithmuserklärungen. Die meisten Erklärungen werden in einer Textform präsentiert, die in natürlicher Sprache verfasst ist. In verschiedenen Fällen werden Erklärungen in multimedialer Form dargestellt, als Tabellen (z.B. Tag-Erklärungen von Bilgic und Mooney (2005)), Grafiken (z.B. soziale Erklärungen von Quijano-Sanchez et al. (2017)), Sternebewertungen (z.B. Erklärungen im Neighbor Stil von Coba et al. (2018)) oder selektive Hervorhebungen (z.B. Erklärungen zum Einfluss von Lai und Tan (2019)). Nur Kaptein et al. (2017) wählten die verbale Präsentationsform, indem sie ihren Roboter seine eigenen Handlungen verbal erklären ließen. Zudem werden Erklärungen am häufigsten automatisch zusammen mit dem Ergebnis des Systems präsentiert. Am zweithäufigsten werden Erklärungen angezeigt, nachdem der Benutzer sie explizit angefordert hat. Die Directive bzw. Richtlinienerklärungen von Hadasch et al. (2016) sind die einzigen Erklärungen, die intelligent präsentiert werden, und zwar genau in dem Moment, in dem das System erkennt, dass der Benutzer dem vorgegebenen Prozess nicht folgt. Die Ergebnisse dieser Literaturanalyse zeigen, dass Erklärungen den Benutzer in mehreren Aspekten positiv beeinflussen können (Tabelle 5).

Anhang 10: Beispiele für die Operationalisierung der Erklärungsmethoden in der Literatur

Erklärungsmethode	Textbasiertes Beispiel	Multimediales Beispiel
Justification	"The increasing trend could signify either that the firm's ability to manage current or that the firm's products are not performing as well in the market. This is because the increasing trend can indicate: 1) higher sales to credit customers or lower sales to cash customers, 2) higher credit limits or longer payment term being offered to customers []"(Dhaliwal & Benbasat, 1996, p. 360)	

Rule Trace	"This conclusion was reached based on the following evaluations:  1. the day sales in receivables ratio has increased from 4.8 to 15.9 over the last five years;  2. the accounts receivables turnover has declined from 76.7 to 23.0 over the last five years []" (Dhaliwal & Benbasat, 1996, p. 360)	Selective highlighting of corresponding portions of an incident (Ehrlich et al., 2011, p. 127)
Strategic	"Liquidity analysis represents one of seven types of financial analysis that were undertaken. The following four assesments served as the basis for the conclusions pertaining to the firm's liquidity position:  1) asses of working capital yielded in a posisitive result, 2) assessment of receivables management yielded in a negative result []" (Dhaliwal & Benbasat, 1996, p. 360)	
Tradeoff	"Most digital cameras can take pictures beyond the immediate vicinity. However, cameras capable of taking pictures from very far away will be more expensive. As well, your choices will be more limited (only about 20 percent). Hence, be careful not to overestimate your needs."  (Wang & Benbasat, 2007, p. 225)	
Neighbor Style		Distribution of star ratings of the recommended movie based on rat- ing from neighbors (Coba et al., 2018, p. 72)
Definition	"A drug sensitivity is an observable deviation that causes something dangerous that is also caused by the drug." (Gregor & Benbasat, 1999, p. 503)	
Confidence	"The computer is 93% confident you'll like this song" (Kulesza et al., 2013, p. 6)	Star-Rating which shows the confidence of the system in its recommendation (Herlocker et al., 2000, p. 248)
Social	"Although we have predicted that your preference for this particular item is not very high, your fried V, who you highly trust, thinks that it is a very good options. Besides, Z really wants this item to be chosen and remember that last time he was the one who gave in." (QuijanoSanchez et al., 2017, p. 43)	Arrows between avatar of user and neighbors to show strength of social connection (Qui- janoSanchez et al., 2017, p. 43)
Feature	"Although this movie does not belong to any of your preferred genres(s), it belongs to the genre(s): Documentary. This movie stars Ben Kingsley, Ralph Fiennes and Liam Neeson your favorite actor(s). (Tintarev & Masthoff, 2012, p. 409)	
Tag		<ul> <li>A table consisting of tags, star rating displaying preference and pro- gress bars representing relevance of each tag (Vig et al., 2008, p. 52)</li> </ul>

Influence		<ul> <li>A table consisting of books with corresponding rating of user and influence on the current recom- mendation (Bilgic &amp; Mooney, 2005, p. 156)</li> </ul>
		<ul> <li>Color highlighting of words which were used by model to classify re- port as well as a corresponding colored heatmap for reference of the weighted importance of the highlighted words (Lai &amp; Tan, 2019, p. 32)</li> </ul>
		<ul> <li>Show on which parts of an image the classifier based his decision (Ribeiro et al., 2016, p. 1143)</li> </ul>
Algorithm	"The computer looked at what the green songs tend to have in common, and what makes them different from the red songs. It did this 100 times, each time randomly picking songs from the red and green groups. In 93 of the 100 times, it predicted that you'll like this song. Here are four of the predictions; foreach one, the computer thinks that you'll like songs with all of these characteristics." (Kulesza et al., 2013, p. 6)	
FAQ	"Any alternatives to this prescription? - There is no effective alternative to Fennodil at the moment, but after the ulcer has healed, you should adopt a more suitable diet, and try to lead a less stressful lifestyle." (Berry et al., 1995, p. 426)	
Directive	"When sending e-mails, you should comply with the DMR process." (Hadasch et al., 2016, p. 37)	Process tree which shows different steps and decision points (Hadasch et al., 2016, p. 35)
"Why not"	"Output not classified as Exercising, because Pace ≤ 3, but not Body Temperature > 5" (Lim et al., 2009, p. 2121)	(