

Identifikation und Bewertung von datenbasierten Anwendungsfällen für die Montage

Evaluation von Data Analytics Anwendungsfällen

T. Stahl, F. Wurst, M. F. Huber

Die Identifizierung und Bewertung von Anwendungsfällen im Bereich der Datenanalyse erfordert sowohl datenwissenschaftliche als auch fachliche Expertise, was Unternehmen oft vor Schwierigkeiten stellt. Aufgrund der Komplexität und des ungewissen wirtschaftlichen Nutzens möglicher datenanalytischer Anwendungsfälle gibt es Herausforderungen, die die Realisierung von Data Analytics Projekten erschweren. In diesem Beitrag wird eine Methode zur Identifizierung und Bewertung von Anwendungsfällen der Datenanalyse vorgestellt.

STICHWÖRTER

Montage, Digitalisierung, Automobilindustrie

Identification and evaluation of data-based use cases for assembly – Evaluation of Data Analytics Use Cases

Identifying and realistically evaluating use cases in the field of data analytics requires expertise in both data science and domain knowledge, which often confronts companies with difficulties. Due to the complexity and the uncertain economic benefit of possible data analytic use cases, there are often challenges that make it difficult to realize data analytics projects. This publication presents a method for identifying and evaluating use cases of data analytics.

1 Überblick

Im Hochtechnologiestandort Deutschland behauptet sich der sekundäre Sektor beziehungsweise das produzierende Gewerbe mit einem Anteil von 30 % der Bruttowertschöpfung als eine treibende Kraft der Wirtschaft [1]. Mit einem Umsatz von 429 Milliarden Euro (2020) weist die Automobilindustrie einen Anteil von 23 % des Gesamtumsatzes deutscher Industriebranchen auf und hebt sich somit als Kernindustrie hervor [2]. Im Zuge der digitalen Transformation steigt die Generierung und Verfügbarkeit von Daten in der Produktion substantiell an, wobei die anfallenden Daten bisher nur zu 30 % genutzt werden [3]. Als eine Schlüsseltechnologie eröffnet Data Analytics durch Analysen vorhandener Daten großes Potenzial für Prozess- und Systemoptimierungen [4, 5]. Aufgrund der steigenden Bedeutung des Montagebereichs, der „in seiner Funktion als einer der wichtigsten wertschöpfenden Prozesse wesentlich den Erfolg [...] eines Unternehmens beeinflusst“, ist eine Optimierung der zugrundeliegenden Prozesse mittels Data Analytics ausschlaggebend, um unentdeckte Effizienzpotenziale trotz steigender Komplexität auszuschöpfen [6–8]. Die Identifikation und realistische Bewertung von Anwendungsfällen im Bereich Data Analytics erfordern neben Expertise im Bereich Data Science ausgeprägtes Domänenwissen [vgl. 9]. Um einen nachhaltigen Wettbewerbsvorteil zu erzielen, müssen die Anwendungsfälle wirtschaftlich sowie strategisch hinsichtlich der übergeordneten Unternehmensziele bewertet werden [vgl. 10]. Durch die Komplexität und den unklaren wirtschaftlichen Nutzen möglicher datenanalytischer Anwendungsfälle bestehen oftmals erhebliche Herausforderungen, die

eine Realisierung von Data Analytics Projekten in Unternehmen erschweren [11, 12].

In diesem Beitrag werden Unternehmen dabei unterstützt, Anwendungsfälle von Data Analytics innerhalb eines Montagebereichs zu erkennen sowie die identifizierten datenanalytischen Anwendungsfälle ganzheitlich zu bewerten, um abschließend eine Handlungsempfehlung für erfolgversprechende Projekte abzuleiten. Hierzu wurde das sechsstufige Design Science Research Process Model (DSRPM) von *Pfeffers et al.* verfolgt [13].

2 Grundlagen

2.1 Fahrzeugmontage

Die Relevanz des Montagebereichs im Fahrzeugbau begründet sich in einem Gesamtfertigungszeitanteil von 30 bis 50 % und einer Verursachung von bis zu 70 % der Herstellkosten [14]. Die zunehmende Varianten- und Baureihenanzahl sowie ein stets steigender Kostendruck stellen für die Fahrzeugmontage eine besondere Herausforderung dar [6]. Eine höhere Variantenvielfalt steigert die Komplexität, beispielsweise bei Montage verschiedener Fahrzeugtypen und kundenindividueller Ausstattungen auf einer Montagelinie. [15]. Aufgrund der hohen Anforderungen an die Flexibilität der Prozesse und schwer automatisierbaren Bewegungsabläufen befindet sich der durchschnittliche Automatisierungsgrad der Endmontage im einstelligen Prozentbereich [7, 16, 17]. Die Kostensituation der Fahrzeugendmontage unterscheidet sich von den hoch automatisierten Gewerken des Automobilbaus dahingehend, dass die Personalkosten aus manuellen Tätigkeiten üblicherweise den größten Anteil abbilden, die Investitionskosten einer Montagelinie nach wenigen Jahren übersteigen und den

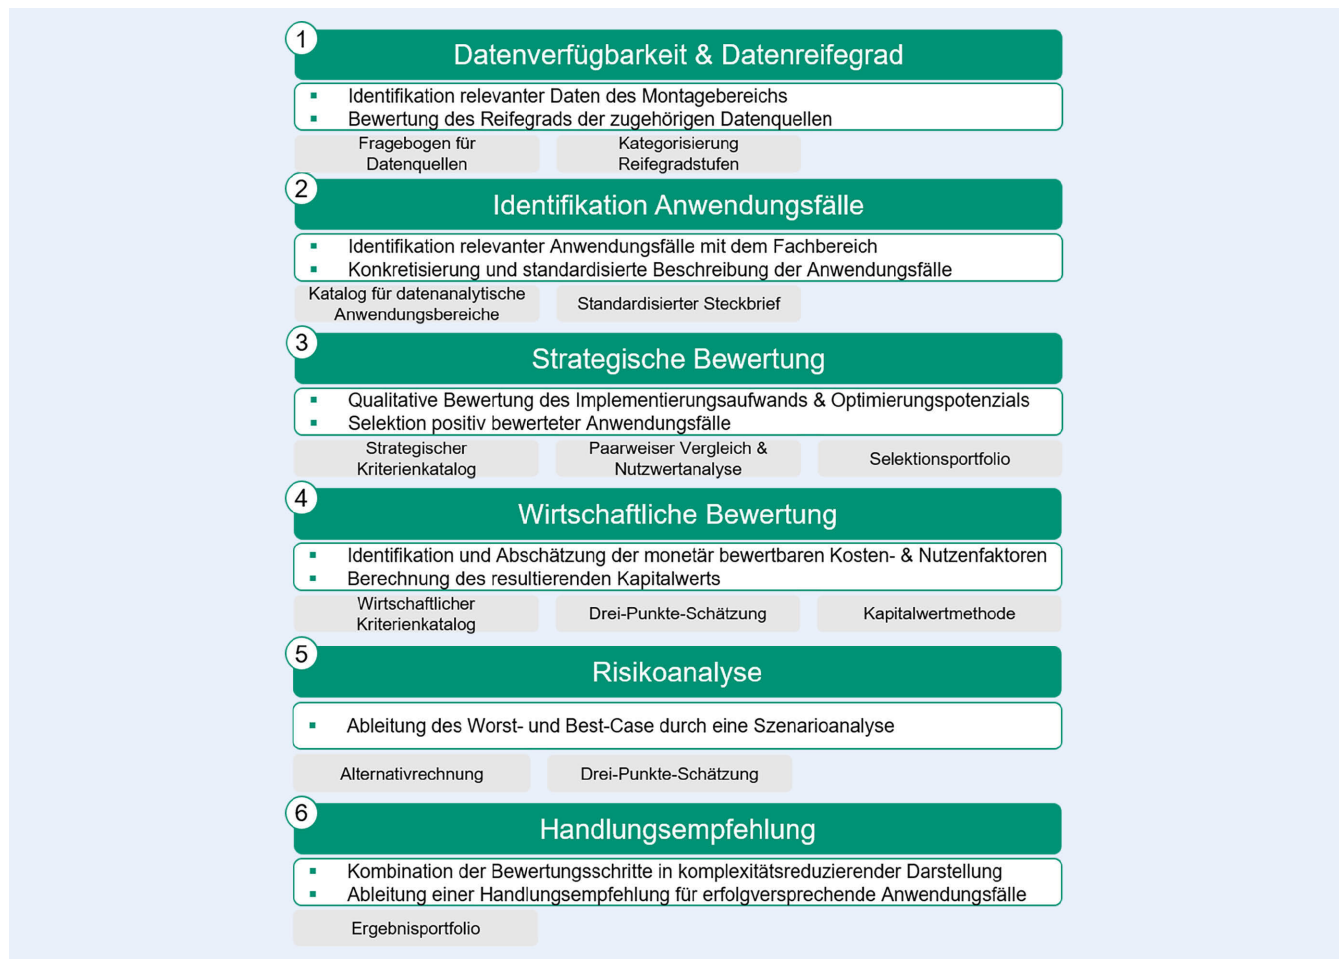


Bild 1. Gesamtübersicht MEADA mit relevanten Werkzeugen. Grafik: Fraunhofer IPA

fehleranfälligsten Produktionsbereich darstellen [14, 17]. Die Optimierungspotenziale werden in der Praxis in die gegenläufigen Zielgrößen Qualität, Zeit, Kosten und Mitarbeiter zusammengefasst [6, 18].

2.1.1 Data Analytics

Durch die zunehmende Vernetzung in Zeiten der digitalen Transformation stehen große Mengen an Produktionsdaten zur Entscheidungsfindung zur Verfügung. Ziel von Data Analytics ist die Optimierung von Prozessen mit Daten [19–21]. Der typische Ablauf von Data Analytics wird in deskriptive, diagnostische, prädiktive und präskriptive Analysen aufgeteilt, die aufeinander aufbauen [5]. Deskriptive Ansätze schließen auf Basis vorliegender Daten auf historische Systemzustände und beschreiben diese in einer anschaulichen Form [5, 22]. Diagnostische Ansätze zeigen die Wirkzusammenhänge aus historischen Daten auf, um ein erkanntes Verhalten zu erklären. Während deskriptive und diagnostische Ansätze ausschließlich vergangenheits- oder gegenwartsorientiert sind, fokussieren sich prädiktive sowie präskriptive Ansätze auf Problemstellungen der Zukunft [23]. Prädiktive Analysen bilden auf Basis historischer Daten Prognosen um zukünftige Ereignisse mithilfe von statistischen Methoden oder maschinellem Lernen, vorherzusagen [5, 9, 22]. Die präskriptive Analytik stellt die ausgeprägteste Form der Entscheidungsunterstützung in einem Unternehmen dar. Ziel ist die fundierte Ablei-

tung konkreter Maßnahmen, um ein definiertes Geschäftsziel zu erreichen [5]. Die präskriptive Analytik nutzt Methoden der diagnostischen oder prädiktiven Analyse als Grundbestandteile und kombiniert diese mit Optimierungs- oder Simulationsmethoden [24].

3 Methode

3.1 Anforderungen und bestehende Methoden

Bei der Entwicklung der Methode ergeben sich allgemeine Anforderungen, Anforderungen an die Durchführung der Bewertung [25] und kontextspezifische Anforderungen.

- Allgemeine Anforderungen: Adäquater Aufwand [26, 27], Benutzerfreundlichkeit [28, 29], intuitive Visualisierung [30].
- Bewertungsanforderungen: Quantitative Wirtschaftlichkeitsanalyse [28, 31], qualitative strategische Bewertung [26, 28, 31, 32], systematische Selektion [28], Unsicherheitstoleranz [32], situative Anpassung [26, 25].
- Kontextspezifische Anforderungen: Montagerelevante Zielgrößen [6, 28, 33, 34], Hilfestellung zur Identifikation potenzieller Anwendungsfälle [11, 35], Berücksichtigung der Datenverfügbarkeit und -qualität [36], Unterstützung zur Identifikation des Nutzenpotenzials [31, 37], Berücksichtigung des Synergiepotenzials [38].

In der Literatur verfügbare Evaluationsmethoden [11, 25, 28, 37] wurden hinsichtlich der Erfüllung der aufgelisteten Anforderun-

Tabelle. Anwendungsbereiche für die vier Reifegradstufen.

Überwachen von		Erkennen von		Vorhersagen von		Vorgeben von	
1	qualitätsorientierten Kennzahlen (17, 18)	17	Abweichungen und Einflüssen auf Montagekennzahlen (34, 39)	34	Produktqualität (50)	50	Prozessparametern zur Optimierung der Prozessqualität
2	effizienzorientierten Kennzahlen (17,18)	18	Abweichungen oder Einflüssen relevanter Prozessparameter (34, 35, 36, 37, 39, 41, 42)	35	Prozessgüte eines Betriebsmittels/eines Prozessschrittes (50, 51, 52)	51	Parametern/Maßnahmen zur Optimierung von Prozesszeiten
3	Prozessparametern (18, 23)	19	Abweichungen oder Einflüssen relevanter Kalibrierungsparameter (38)	36	Prozesszeiten (51, 53)	52	Kalibrierungsparametern oder -zeitpunkten von Betriebsmitteln
4	Kalibrierungsparametern (19)	20	Abweichungen oder Trends der Prozessschritte (40, 41)	37	Prozessparametern von Betriebsmitteln (50, 51, 53)	53	Maßnahmen für die Optimierung von Prozessschritten
5	Prozessschritten (20, 21, 22)	21	Schwachstellen im Prozessablauf (41)	38	Kalibrierungsparametern oder -zeitpunkten von Betriebsmitteln (52)	54	Vermeidungsmaßnahmen für Prozessfehler
6	Überwachung der Datenübertragung (21)	22	Abweichungen und Einflüssen der Montagefehler (41)	39	Leistungsverbesserung spezifischer Maßnahmen (51, 53)	55	Instandhaltungsmaßnahmen
7	Montagefehlern (21, 22)	23	Abweichungen und Ursachen der Betriebsmittelzustände (42)	40	Prozessschritten (53)	56	Maßnahmen zur Erhöhung von Betriebsmittelverfügbarkeiten
8	Betriebsmittelzuständen (23, 27)	24	Abweichungen und Trends der Betriebsmittelverfügbarkeit (39, 42, 43)	41	Fehlerrücktritten im Prozess (50, 55)	57	Maßnahmen zur Optimierung des Betriebsmittelenergieverbrauchs
9	Betriebsmittelverfügbarkeit (17, 24, 25, 27)	25	Einflüssen und Ursachen bei Auffälligkeiten der Betriebsmittelverfügbarkeit (42, 43)	42	Betriebsmittelzuständen (55, 56)	58	Maßnahmen zur Optimierung der Materialbereitstellung
10	Energieverbrauch (26, 27)	26	Abweichungen und Ursachen des Energieverbrauchs (44)	43	Betriebsmittelverfügbarkeiten (55, 56)	59	Maßnahmen zur Optimierung der Fördertechnik
11	Materialbereitstellung (28)	27	Charakteristika verschiedener Betriebsmittel (39, 41)	44	Betriebsmittelenergiebedarfen (57)	60	Maßnahmen zur Optimierung der Arbeitssicherheit
12	Fördertechnik des Produkts (29)	28	Abweichungen und Ursachen der Materialbereitstellung (45)	45	Engpässen der Materialbereitstellung (58, 59)	61	Maßnahmen zur Optimierung der Arbeitsergonomie
13	Arbeitssicherheit (30)	29	Abweichungen und Ursachen bei Auffälligkeiten der Fördertechnik des Produkts (46)	46	Auffälligkeiten der Fördertechnik des Produkts (59)	62	Maßnahmen zur Reduzierung der Einflüsse von Umgebungsbedingungen
14	Überwachung der Arbeitsergonomie (31)	30	Abweichungen und Ursachen der Arbeitssicherheit (47)	47	Gefährdungen für Montage-mitarbeiter (60, 61)		
15	Umgebungsbedingungen (32)	31	Abweichungen und Ursachen der Arbeitsergonomie (48)	48	unergonomischen Aktivitäten von Montagemitarbeitern (61)		
16	Produktvarianten (33)	32	Abweichungen und Ursachen bei Auffälligkeiten der Umgebungsbedingungen (49)	49	Umgebungsbedingungen (62)		
		33	Charakteristika verschiedener Produktvarianten (34, 36)				

gen untersucht. Es existieren Methoden mit unterschiedlichen Schwerpunkten, die die Anforderungen teilweise erfüllen. Der Anforderungsvergleich legt jedoch nahe, dass es keine Methode für die Evaluation möglicher Anwendungsfälle von Data Analytics in der Montage gibt, die alle Anforderungen ausreichend thematisiert. Die zu entwickelnde Methode konkurriert nicht mit existierenden Prozessmodellen, wie CRISP-DM [39], sondern wird als

projektübergreifende Erweiterung der Geschäftsverständnis-Phase betrachtet.

3.2 Aufbau der Methode

Das übergeordnete Ziel „Methode zur Evaluation von Anwendungsfällen von Data Analytics“ (MEADA) ist die Ableitung

Zielgrößen				
Kosten	Zeit	Qualität	Mitarbeiter	Synergien
Optimierungskriterien				
Betriebsmittelproduktivität	Durchlaufzeit	Ausschuss und Nacharbeit	Arbeitsqualität und -motivation	Datenreifegrad
Energieverbrauch	Rüstzeit	Prozessqualität	Arbeitsautonomie	Wissensgenerierung
Instandhaltungskosten	Prozesszeit	Prozessverlässlichkeit	Arbeitssicherheit	Strategie- und Imagefit
Materialbedarf	Reaktionszeit	Transparenzsteigerung	Personalproduktivität	
Garantie & Rückrufrufen	Prüf- & Kalibrierungszeit	Kundenzufriedenheit	Arbeitsergonomie	
	Arbeits- & Analysezeit			
	Betriebsmittelverfügbarkeit			
Implementierungskriterien				
Automatisierungsgrad	Einführungszeit	Einhaltung von Standards	Qualifizierung	Skalierbarkeit
Wirtschaftlicher Aufwand			Organisatorische Einbindung	Weiterentwicklungspotenzial
Flächenbedarf			Akzeptanz	Weiterentwicklungs-Know-How
Energiebedarf			Datenschutz	Technischer Aufwand
			Know-How	Datenverfügbarkeit

Bild 2. Katalog für strategische Bewertungskriterien. Grafik: in Anlehnung an Liebrecht [28]

datenanalytischer Anwendungsfälle hinsichtlich strategischer und wirtschaftlicher Kriterien. Die grundlegende Struktur der Methode leitet sich vom Trichtermodell ab[11]: Im Verlauf der Methode werden potenzielle Anwendungsfälle aufgrund diverser Selektionskriterien ausgeschlossen, um eine Aufwandsreduzierung zu erzielen. Als methodische Begleitung werden qualitative Bewertungsmethoden herangezogen. Mit fortschreitender Konkretisierung der Anwendungsfälle müssen quantitative Methoden hinzugezogen werden, um eine fundierte Entscheidung zu erlauben [40]. Die einzelnen Schritte und Werkzeuge von MEADA werden in **Bild 1** vorgestellt. Während die Bewertung der Datenverfügbarkeit und des Datenreifegrads sowie die Identifikation der Anwendungsfälle einmalig anfallen, werden Teilaspekte der strategischen Bewertung, die wirtschaftliche Bewertung und die Risikoanalyse für jeden identifizierten Anwendungsfall durchgeführt.

Schritt 1 – Datenverfügbarkeit und Datenreifegrad: Im ersten Schritt werden Daten innerhalb des Betrachtungsrahmens identifiziert und Datenkategorien zugeordnet. Im Anschluss werden die Datenquellen anhand eines Fragebogens hinsichtlich definierter Reifegradstufen kategorisiert [36]. Zur Einordnung der Datenquellen in die Reifegradstufen wird zwischen den Reifegradkategorien Datenerfassung, -bereitstellung, -formate, -darstellung, -kodierung, -umfang sowie -konsistenz differenziert [36]. Der Fragebogen ermöglicht die Einordnung bestehender Daten in die vier Analysestufen der Datenanalyse:

- Reifegradstufe 1: Deskriptive Reife
- Reifegradstufe 2: Diagnostische Reife
- Reifegradstufe 3: Prädiktive Reife
- Reifegradstufe 4: Präskriptive Reife

Schritt 2 – Identifikation der Anwendungsfälle: Im zweiten Schritt werden mit dem zugehörigen Fachbereich des Betrachtungsrahmens relevante Anwendungsfälle von Data Analytics identifiziert. Zur Hilfestellung der Identifikation wurde ein Katalog mit 62 potenziellen Anwendungsfällen entwickelt (**Tabelle**).

Reifegradstufe 1 – Beschreibt die Überwachung, Verfolgung und Visualisierung produkt- und montagerelevanter Informationen in Bezug auf Kenngrößen, Ereignisse und Entitäten [41]. Die Informationen werden zur Entscheidungsunterstützung genutzt, um Auffälligkeiten der Montageprozesse manuell zu identifizieren und geeignete Maßnahmen reaktiv zu ergreifen.

Reifegradstufe 2 – Beschreibt die Analyse vorliegender Daten für das Erkennen kritischer Charakteristika, Trends und Abweichungen sowie die Identifikation relevanter Einflüsse oder Ursachen in Bezug auf Kenngrößen, Ereignisse und Entitäten [41]. Die identifizierten Ursachen, Abweichungen, Trends oder Charakteristika werden zur Entscheidungsunterstützung genutzt, um geeignete Maßnahmen reaktiv abzuleiten.

Reifegradstufe 3 – Beschreibt die Generierung von Modellen aus historischen Daten für Vorhersagen über Kenngrößen, Ereignisse und Entitäten [41]. Die Vorhersagen werden als Grundlage für die Entscheidungsunterstützung genutzt, um frühzeitig Auffälligkeiten oder Planabweichungen der Montageprozesse abzuleiten und somit proaktiv Maßnahmen einzuleiten.

Reifegradstufe 4 – Beschreibt die Generierung von Modellen aus historischen Daten für die Ermittlung von Vorgaben für Kenngrößen, Ereignisse und Entitäten [41]. Die Vorgaben sind proaktive Entscheidungsempfehlungen für Maßnahmen oder

Entscheidungsautomatisierungen zur Optimierung der Montageprozesse.

Schritt 3 – Strategische Bewertung: Im dritten Schritt erfolgt eine qualitative Bewertung des Implementierungsaufwands sowie des erwarteten Optimierungspotenzials der Anwendungsfälle. Nach der Auswahl relevanter Kriterien aus einem strategischen Kriterienkatalog (das Autorenteam empfiehlt je fünf Optimierungs- und Implementierungskriterien aus **Bild 2**) werden diese durch einen paarweisen Vergleich gewichtet [42]. Implementierungsaufwand und Optimierungspotential werden vom Fachbereich subjektiv auf einer 10er Skala eingeordnet. Die identifizierten Anwendungsfälle werden anhand gewichteter Kriterien bewertet und in einem Selektionsportfolio in Anlehnung an Pfeiffer visualisiert [43]. Basierend auf der strategischen Bewertung erfolgt eine Vorauswahl geeigneter Anwendungsfälle (**Bild 3**). Der Aufwand der Methode kann durch Selektion der Anwendungsfälle reduziert werden. Aus der Praxis empfiehlt es sich bis zu drei Anwendungsfälle weiterzuverfolgen.

Schritt 4 – Wirtschaftliche Bewertung: Nach Selektion der strategisch positiv bewerteten Anwendungsfälle werden die quantitativ bewertbaren Kostenfaktoren anhand eines wirtschaftlichen Kriterienkatalogs abgeschätzt. Die Kostenfaktoren beschreiben alle Aufwände (dispositive Aufwände, Investitionskosten, Betriebskosten) [28, 34, 37], die entstehen um den jeweiligen Anwendungsfall im Unternehmen umzusetzen (Datenerfassung, Datenintegration, Datenhaltung, Datenanalyse, Planung & Betrieb) [44–46]. Daraufhin werden die Nutzenfaktoren identifiziert und abgeschätzt. Die Nutzenfaktoren beschreiben alle finanziellen Faktoren, die sich durch die Umsetzung des jeweiligen Anwendungsfalles positiv auf die Montage auswirken. Hierbei kommt das Drei-Punkte-Schätzverfahren zum Einsatz [32], um die vorhandene Unsicherheit zu berücksichtigen. Abschließend wird die Kapitalwertmethode [47] angewendet, um eine monetäre Beurteilung zu ermöglichen (**Bild 4**).

Schritt 5 – Risikoanalyse: Durch Berücksichtigung des Worst- und Best-Case pro Anwendungsfall wird die wirtschaftliche Bewertung durch eine Risikoanalyse erweitert. Auf Basis des Drei-Punkte-Schätzverfahrens aus dem vierten Schritt wird eine Alternativrechnung durchgeführt [48]. Durch die Alternativrechnung werden somit mögliche positive und negative Entwicklungen der wirtschaftlichen Bewertung aufgezeigt.

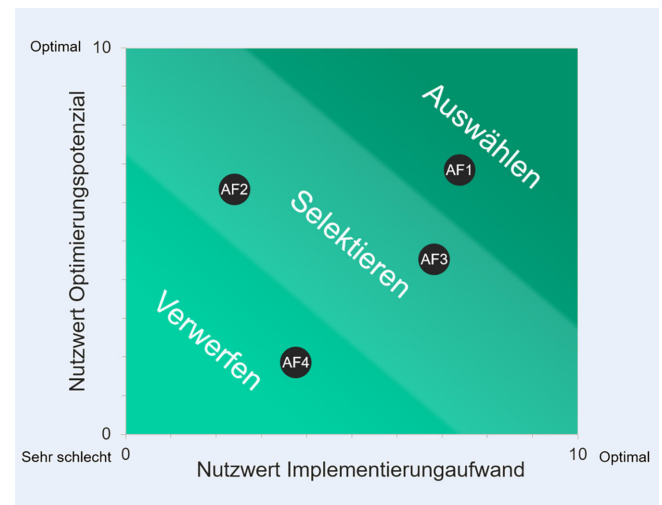


Bild 3. Selektionsportfolio für die identifizierten Anwendungsfälle (AF1 bis 4). Grafik: Fraunhofer IPA

Schritt 6 – Handlungsempfehlung: Die strategische und wirtschaftliche Bewertung sowie die Risikoanalyse werden in einem zweidimensionalen Ergebnisportfolio kombiniert [25], um eine Handlungsempfehlung für die erfolgversprechendsten Anwendungsfälle auszusprechen (**Bild 5**). Der Kapitalwert gepaart mit der Risikoanalyse ist primäres Kriterium zur Ableitung der Handlungsempfehlung. Um Anwendungsfälle mit Überschneidungen beim Kapitalwert zu vergleichen, wird der strategische Nutzwert ergänzt. Der strategische Nutzwert ist der Mittelwert aus Optimierungspotential und Implementierungsaufwand in Schritt 3 und ergänzt die monetäre Bewertung um die subjektive Wahrnehmung der Fachbereiche.

4 Zusammenfassung

Als eine Schlüsseltechnologie der Industrie 4.0 ermöglicht Data Analytics durch zielgerichtete Analysen vorhandener Daten großes Potenzial für Prozess- und Systemoptimierungen im Montagebereich. Aufgrund der steigenden Komplexität des Montagebereichs ist eine Optimierung der zugrundeliegenden Prozesse mittels Data Analytics ausschlaggebend, um unentdeckte Effizienzpotenziale auszuschöpfen. Durch die Komplexität und den




Bild 4. Verlauf des Kapitalwerts eines exemplarischen Anwendungsfalles für drei Szenarien. Grafik: Fraunhofer IPA




Bild 5. Ergebnisportfolio zur Ableitung der Handlungsempfehlung für die Anwendungsfälle (AF1 bis AF4). Grafik: Fraunhofer IPA

unklaren wirtschaftlichen Nutzen möglicher datenanalytischer Anwendungsfälle bestehen oftmals erhebliche Herausforderungen, die eine Realisierung von Data Analytics Projekten in Unternehmen erschweren. Aus diesem Grund wurde eine Methode zur Identifikation und Bewertung potenzieller Anwendungsfälle von Data Analytics im operativen Betrieb der Montage entwickelt.

Obwohl MEADA in erster Linie für die Erfassung von Big Data-Anwendungsfällen in der Montage entwickelt wurde, hat sich die Anwendbarkeit in anderen Bereichen bewährt. Die Methode wurde bereits in sieben Unternehmen, davon sechs im Rahmen der AI-Explorer, zur Identifikation von KI-Anwendungsfällen angewendet (KI-Fortschrittszentrum „Lernende Systeme und Kognitive Robotik“, Ministerium für Wirtschaft, Arbeit und Tourismus Baden-Württemberg). Aus dem Kundenfeedback konnten wir entnehmen, dass die Anforderungen bis auf den adäquaten Aufwand erfüllt werden: Die Erfassung des Datenreife-grads aus Schritt 1 ist trotz Fragebogen [36] in der Praxis sehr aufwändig. Außerdem ist die Abschätzung der Nutzenpotenziale in Schritt 4 nicht immer mit der Drei-Punkte-Schätzung möglich, so dass umfangreiche Prozessanalysen (Vergleich zwischen SOLL- und IST-Prozess) notwendig werden. Der kritische Erfolgsfaktor der Methode ist daher die Zusammensetzung des Projektteams: operative Mitarbeiter aus der Produktion (Schätzung oder Analyse des Nutzens) zusammen mit Data Scientists (Schätzung oder Analyse des Aufwands) und Business Experts. Die Auswahl der Optimierungs- und Umsetzungskriterien in Schritt 3 führt zwar zu schnellen Ergebnissen, ist aber sehr subjektiv und würde bei anderen Projektbeteiligten zu einer anderen Auswahl und Gewichtung führen. Schließlich ist zu beachten, dass die Methode in erster Linie für die Optimierung interner Prozesse geeignet ist. Für die Handlungsempfehlung (Schritt 6) hat sich als Alternative auch eine tabellarische Gegenüberstellung bewährt.

Literatur

- [1] Statista: Anteil der Wirtschaftsbereiche am Bruttoinlandsprodukt. Internet: <https://de.statista.com/statistik/daten/studie/241480/umfrage/umsaetze-der-wichtigsten-industriebranchen-in-deutschland/>. Zugriff am 01.06.2022
- [2] Statista: Umsätze der wichtigsten Industriebranchen in Deutschland in den Jahren von 2017 bis 2019. Internet: <https://de.statista.com/statistik/daten/studie/241480/umfrage/umsaetze-der-wichtigsten-industriebranchen-in-deutschland/>. Zugriff am 01.06.2022
- [3] Kearney: Industrie 4.0: 350 Mrd. EUR zusätzlich dank Robotik, Wearables and Co. Internet: <https://www.presseportal.de/pm/15196/3584377>. Zugriff am 31.05.2022
- [4] Dai, H.-N.; Wang, H.; Xu, G. et al.: Big data analytics for manufacturing internet of things: opportunities, challenges and enabling technologies. Enterprise Information Systems (2019)
- [5] Freitag, M.; Kück, M.; Alla, A. A. et al.: Potenziale von Data Science. Produktion und Logistik 2015
- [6] Feldmann, K. (Hrsg.): Montage strategisch ausrichten. Praxisbeispiele marktorientierter Prozesse und Strukturen. Berlin, Heidelberg: Springer Berlin 2004
- [7] Huber, W.: Industrie 4.0 in der Automobilproduktion. Ein Praxisbuch. Wiesbaden: Springer Vieweg 2016
- [8] Palm, D.; Ohlhausen, P.; Braun, A. et al.: Datengetriebene Produktions-optimierung in der Montage. Zeitschrift für wirtschaftlichen Fabrik-betrieb (2018) 113, S. 518–521
- [9] Kröckel, J.: Data Analytics in Produktion und Logistik. Würzburg, Ann Arbor, Michigan: Vogel Business Media; ProQuest 2019
- [10] Wagner, R. M. (Hrsg.): INDUSTRIE 4.0 für die Praxis. Wiesbaden: Springer Gabler 2018
- [11] Kohl, M.; Malik, B.; Lopitzsch, J. et al.: Auswahl- und Priorisierungsmodell für Industrie 4.0-Use Cases in der Logistik, 2019
- [12] Meister, M.; Beßle, J.; Cviko, A. et al.: Manufacturing Analytics for problem-solving processes in production. Procedia CIRP 81 (2019), S. 1–6
- [13] Peffers, K.; Tuunanen, T.; Gengler, C. E. et al.: Design Science Research Process: A Model for Producing and Presenting Information Systems Research (2020), S. 83–106
- [14] Lotter, B.; Wiendahl, H.-P. (Hrsg.): Montage in der industriellen Produktion. Ein Handbuch für die Praxis. Berlin, New York: Springer 2006
- [15] Weidemann, U.: Montagecluster zur Strukturierung der Fahrzeugendmontage – Eine Methode zur frühzeitigen Planung und Auslegung von Endmontagelinien, 2017
- [16] Motzer, D.: Strukturalternative für die Aggregateaufrüstung einer automobilen Fertigung. Wiesbaden: Springer Fachmedien Wiesbaden 2015
- [17] Roscher, J.: Bewertung von Flexibilitätsstrategien für die Endmontage in der Automobilindustrie, 2008
- [18] Westkämper, E.; Schloske, A.: Fertigungs- und Fabrikbetrieb. In: Bender, B.; Göhlich, D. (Hrsg.): DUBBEL TASCHENBUCH FR DEN MASCHINENBAU GRUNDLAGEN UND TABELLEN. [S.l.]: Morgan Kaufmann 2020
- [19] Runkler, T. A.: Data Analytics. Wiesbaden: Springer Fachmedien Wiesbaden 2020
- [20] Angée, S.; Lozano-Argel, S. I.; Montoya-Munera, E. N. et al.: Towards an Improved ASUM-DM Process Methodology for Cross-Disciplinary Multi-organization Big Data & Analytics Projects. In: Uden, L.; Hadzima, B.; Ting, I.-H. (Hrsg.): Knowledge Management in Organizations. Cham: Springer International Publishing 2018, S. 613–624
- [21] Zakir, J.; Seymour, T.; Berg, K.: BIG DATA ANALYTICS. Issues in Information Systems (2015) 2
- [22] Rajaraman, V.: Big data analytics. Resonance 21 (2016) 8, S. 695–716

- [23] Banerjee, A.; Bandyopadhyay, T.; Acharya, P.: Data Analytics: Hyped Up Aspirations or True Potential? *Vikalpa: The Journal for Decision Makers* 38 (2013) 4, S. 1–12
- [24] Dorschel, J.: *Praxishandbuch Big Data. Wirtschaft – Recht – Technik.* Wiesbaden: Springer Fachmedien Wiesbaden 2015
- [25] Messerle, M.: Methodik zur Identifizierung der erfolgversprechendsten Produktideen in den frühen Phasen des Produktentwicklungsprozesses, 2016
- [26] Ulrich, M.; Bachlechner, D.: Wirtschaftliche Bewertung von KI in der Praxis – Status Quo, methodische Ansätze und Handlungsempfehlungen. *HMD Praxis der Wirtschaftsinformatik* 57 (2020) 1, S. 46–59
- [27] Eisenführ, F.; Weber, M.: *Rationales Entscheiden.* Berlin, Heidelberg: Springer Berlin 1999
- [28] Liebrecht, C.: Entscheidungsunterstützung für den Industrie 4.0-Methodeneinsatz – Strukturierung, Bewertung und Ableitung von Implementierungsreihenfolgen, 2020
- [29] Kelleher, J. D.; Tierney, B.: *Data science.* Cambridge, Massachusetts, London, England: The MIT Press 2018
- [30] Hall, K.: *Ganzheitliche Technologiebewertung.* Wiesbaden: Deutscher Universitätsverlag 2002
- [31] Zelewski, S.: Ansätze zur Bewertung des Einsatzes künstlicher Intelligenz in Industrieunternehmen. 1988
- [32] Schuh, G.; Klappert, S.: *Technologiemanagement. Handbuch Produktion und Management 2.* Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg 2011
- [33] Hering, E.; Triemel, J.; Blank, H.-P. (Hrsg.): *Qualitätsmanagement für Ingenieure.* Berlin: Springer Berlin 2013
- [34] Dombrowski, U.; Krenkel, P.; Falkner, A. et al.: Prozessorientierte Potenzialanalyse von Industrie 4.0-Technologien. *ZWF* 113 (2018) 3, S. 107–111
- [35] Massmann, M.; Meyer, M.; Frank, M. et al.: Framework for Data Analytics in Data-Driven Product Planning. *Procedia Manufacturing* 52 (2020), S. 350–355
- [36] Bernerstätter, R.: Reifegradmodell zur Bewertung der Inputfaktoren für datenanalytische Anwendungen – Konzeptionierung am Beispiel der Schwachstellenanalyse. Dissertation, Montanuniversität Leoben, 2019
- [37] Anandarajan, A.; Wen, H. J.: Evaluation of information technology investment. *Management Decision* 37 (1999) 4, S. 329–339
- [38] Joppen, R.; Enzberg, S. von; Kühn, A. et al.: Investitionsentscheidungen vor dem Hintergrund der Digitalisierung am Beispiel Schaltschrankbau. *ZWF* 114 (2019) 7–8, S. 483–487
- [39] Wirth, R.; Hipp, J.: CRISP-DM: Towards a standard process model for data mining. *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining* (2000), S. 29–40
- [40] Warschat, J.; Schimpf, S.; Korell, M. (Hrsg.): *Technologien frühzeitig erkennen, Nutzenpotenziale systematisch bewerten. Methoden, Organisation, semantische Werkzeuge zur Informationsgewinnung und* -speicherung; Ergebnisse des Verbundforschungsprojektes syncTech – synchronisierte Technologieadaption als Treiber der strategischen Produktinnovation. Stuttgart: Fraunhofer-Verl. 2015
- [41] Gölzer, P.: *Big Data in Industrie 4.0-Eine strukturierte Aufarbeitung von Anforderungen, Anwendungsfällen und deren Umsetzung.* Dissertation, Friedrich-Alexander-Universität, 2017
- [42] Sonntag, A.: PROMIDIS Handlungsleitfaden-Instrument Paarweiser
- [43] Hahn, D.; Taylor, B.: *Strategische Unternehmensplanung – strategische Unternehmensführung Stand und Entwicklungstendenzen.* Berlin, Heidelberg: Springer 2006
- [44] Marschall, T.; Baars: *Pi-Architektur-Agiles Datenmanagement in Big-Data-Umgebungen.* *BI-Spektrum* (2017) 1, S. 36–40
- [45] bitkom: *Big-Data-Technologien – Wissen für Entscheider.* Internet: <http://www.kmu-digital.eu/de/service-kompetenz/publikationen/dokumente/broschueren/4-big-data-technologien-wissen-fuer-entscheider/file>. Zugriff am 25.02.2022
- [46] Kühn, A.; Joppen, R.; Reinhart, F. et al.: *Analytics Canvas – A Framework for the Design and Specification of Data Analytics Projects.* *Procedia CIRP* 70 (2018), S. 162–167
- [47] Schuster: *Investitionsrechnung: Kapitalwert, Zinsfuß, Annuität, Amortisation.* Berlin, Heidelberg: Springer Berlin Heidelberg 2017
- [48] Project Management Institute: *A guide to the project management body of knowledge (PMBOK guide)*

Tobias Stahl , M. Sc.

Ferdinand Wurst, M. Sc.

Prof. Dr.-Ing. habil. Marco Huber

Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA
 Nobelstr. 12, 70569 Stuttgart
 Tel. +49 711 / 970-1954
tobias.stahl@ipa.fraunhofer.de
www.ipa.fraunhofer.de

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons
 Namensnennung 4.0 International (CC BY 4.0)