

Anreizsysteme und Ökonomie des Data Sharings

Handlungsfelder des unternehmensübergreifenden Daten-
austausches und Status quo der deutschen Wirtschaft

Projektpartner des IEDS-Projekts

Eine Publikation aus dem Projekt



tu technische universität
dortmund

ZEW

IEDS 



Inhalt

Vorwort	5
Zusammenfassung – Executive Summary	6
1 Innovative Data Economy – Europas Chance durch Datenräume und Data Sharing	8
1.1 Digitalisierung und Data Sharing für Innovationspotenziale nutzen	8
1.2 IDS und Gaia-X – Europäische Dateninfrastruktur als Basis des Data Sharings ..	9
1.3 Data Sharing aus der unternehmensübergreifenden Perspektive	12
1.4 Data Sharing aus der unternehmensinternen Perspektive	16
2 Status Quo der gemeinsamen Datenbewirtschaftung in Deutschland	20
2.1 Data Economy Readiness und gemeinsame Datenbewirtschaftung	20
2.2 Monitoring Gaia-X	25
2.3 Umfrageexperiment Anreizmechanismen	28
3 Anreize und Anforderungen zur Teilnahme am Data Sharing – Forschungsüberblick	30
3.1 Forschungsüberblick »Data Sharing«	30
3.2 Datenstrategien und effizientes Datenmanagement	34
3.3 Datengetriebene Geschäftsmodelle	39
3.4 Datenbewertung	45
3.5 Datenrecht	50
4 Ausblick	54
5 Übersicht über das IEDS-Forschungsprojekt und Projektpartnervorstellung	56
6 Quellenverzeichnis	58
Impressum	67

Vorwort



*Prof. Dr.-Ing. Boris Otto
geschäftsführender Insti-
tutsleiter Fraunhofer ISST
und Inhaber des Lehrstuhls
für Industrielles Informa-
tionsmanagement an der TU
Dortmund*



*Prof. Dr. Michael Hüther
Direktor und Mitglied des
Präsidiums des IW*



*Prof. Dr. Irene Bertschek
Leiterin des ZEW-Forschungs-
bereichs „Digitale Ökonomie“*



*Prof. Dr.-Ing. Prof. e. h.
Wilhelm Bauer
geschäftsführender Insti-
tutsleiter Fraunhofer IAO*

Die Digitalisierung unserer physischen Welt schreitet fortwährend voran. Die Bedeutung von Daten als Treiber der Ökonomie zeigt sich in den Innovationsprozessen von neuen Geschäftsmodellen und digitalen Produkt-Service-Systemen, die immer häufiger nicht von einem Akteur allein vollbracht werden können. Zuletzt hat die Corona-Pandemie illustrativ aufgezeigt, dass die Digitalisierung und Daten eine zentrale Rolle für eine funktionsfähige Wirtschaft, Wissenschaft und Gesellschaft spielen. Föderierte Dienste und Services rücken daher in den Fokus von Industrien und Branchen, um die Chance der digitalen Vernetzung und Kombination von Ressourcen zu nutzen. Der Aufbau von föderierten Datenräumen und Datenökosystemen stehen im Fokus, sowohl in der Datenstrategie der Bundesrepublik Deutschland als auch in der Datenstrategie der Europäischen Kommission. Initiativen wie Gaia-X und die International Data Spaces Association (IDSA) arbeiten an der Vision einer verteilten Dateninfrastruktur unter Wahrung der Datensouveränität.

Jedoch zeigt sich in Datenrauminiciativen, dass viele Unternehmen in ihrer digitalen Reife noch nicht befähigt sind, erfolgreich und nachhaltig an der Datenökonomie teilzunehmen. Das Projekt »Incentives and Economics of Data Sharing – IEDS« soll dem entgegenwirken. Durch wissenschaftliche Erkenntnisse über die Befähigung von Unternehmen zur Teilnahme am Data Sharing und intelligente Anreizsysteme für das Teilen von Daten kann die Weiterentwicklung der Datenökonomie unterstützt werden und neues Potenzial für Deutschland und Europa erschlossen werden.

Zusammen mit unseren Partnern und dem Bundesministerium für Bildung und Forschung möchten wir in diesem Projekt die Möglichkeiten erweitern und Blaupausen liefern, die sowohl Unternehmen als auch Wissenschaft und Gesellschaft nutzen können, um ihre digitalen Reife zu erhöhen und am Data Sharing teilnehmen zu können.



Zusammenfassung – Executive Summary

Zusammenfassung

Die enormen Innovationspotenziale, die Daten Unternehmen sowie der Wissenschaft bieten, werden in Deutschland überwiegend noch nicht genutzt. Häufig sind dabei die Potenziale sowie der Nutzen der jeweiligen Daten nicht bekannt. Zudem hegen vor allem Unternehmen große Bedenken hinsichtlich rechtlicher Fragestellungen und der Datensicherheit. Speziell im Hinblick auf die Entwicklung datengetriebener Geschäftsmodelle fehlt es Unternehmen an einer Betrachtung von Ökosystemen. Ebenso impliziert die Bewertung von Daten erhebliche Herausforderungen, sodass bestehende Verfahren zur Preisfindung von Gütern hier an ihre Grenzen stoßen. Gleichwohl zeigt das Engagement von mittlerweile über 300 Unternehmen innerhalb der Gaia-X-Initiative die zunehmende Bedeutung von Daten für die Wertschöpfung, des strategischen Umgangs mit Daten sowie der dafür notwendigen Infrastrukturen.

Das **Projekt IEDS – Incentives and Economics of Data Sharing** thematisiert die wirtschaftliche Bedeutung von Daten sowie die Möglichkeiten zu deren Austausch, Nutzung und Verwertung im unternehmerischen Kontext. Es zielt darauf ab, die Ausgestaltung von unternehmensübergreifendem Data Sharing voranzutreiben, Anreize für das Teilen von Daten abzuleiten sowie die Weiterentwicklung der Datenökonomie zu unterstützen. Das IEDS Projekt schafft hierzu ein Referenzdokument, in dem die Zusammenhänge von Datenstrategien, datengetriebenen Geschäftsmodellen, Datenbewertung und Datenrecht aufgezeigt werden. Unternehmen unterschiedlicher Größe sollen durch die erarbeiteten Ergebnisse dazu bewegt und befähigt werden, an der Datenwirtschaft und den damit verbundenen Ökosystemen teilzunehmen.

Executive Summary

The enormous potential for innovation offered by data to companies and the scientific community is still largely unused in Germany. Often, this potential and the benefits of the respective data are not known. In addition, companies in particular have major concerns about legal issues and data security. Especially with regard to the development of data-driven business models, companies do not consider ecosystems. Likewise, the valuation of data poses considerable challenges, so that existing procedures for the pricing of goods reach their limits here. However, the involvement of more than 300 companies in the Gaia-X initiative demonstrates the increasing importance of data for value creation, the strategic use of data and the necessary infrastructures.

The project **IEDS – Incentives and Economics of Data Sharing** addresses the economic importance of data for companies as well as the possibilities for its exchange, use, and exploitation in a business context. It aims to advance the design of cross-company data sharing, to derive incentives for data sharing and to support the further development of the data economy. For this purpose, the IEDS project creates a reference document in which the interrelationships of data strategies, data-driven business models, data valuation, and data law are elucidated. Companies of different sizes are to be encouraged and enabled to participate in the data economy and the associated ecosystems by the results produced.



1 Innovative Data Economy – Europas Chance durch Datenräume und Data Sharing

Durch die Nutzung von Datenräumen und die Teilnahme am Data Sharing lassen sich neue Produkte und Dienstleistungen generieren (vgl. Abschnitt 1.1). Schon heute entwickeln Initiativen wie IDSA und Gaia-X u. a. für Unternehmen einen Standard bzw. eine Infrastruktur, um am Data Sharing zu partizipieren (vgl. Abschnitt 1.2). Um Unternehmen dabei zu unterstützen wertschöpfende Aktivitäten mit Hilfe von Data Sharing zu betreiben, wird anschließend die unternehmensübergreifende und -interne Handlungsebene beleuchtet (vgl. Abschnitte 1.3 und 1.4).

1.1 Digitalisierung und Data Sharing für Innovationspotenziale nutzen

Daten bilden die Basis, auf der sich der digitale und technologische Wandel der Gesellschaft und der Wirtschaft vollzieht. Sie sind die Lebensader der wirtschaftlichen Entwicklung und stellen die Grundlage für viele neue Produkte und Dienstleistungen dar (Europäische Kommission 2020a). Die erhöhte Verfügbarkeit von Daten und die Entwicklung neuer Technologien ermöglichen eine Vielzahl einzigartiger Möglichkeiten, um Daten wertschöpfend zu analysieren und zu nutzen (Wilberg et al. 2018). Da Daten weiterhin in bisher unvorstellbaren Mengen produziert werden, verspricht die Digitalisierung zusätzliche Verschiebungen in der strategischen Landschaft von Unternehmen und die Evolution bestehender Geschäftsmodelle.

Anstelle einer Unternehmensstrategie, die vorgibt, welche Daten gesammelt und analysiert werden sollen, tritt in einigen

Fällen ein erheblicher Einfluss der gesammelten und analysierten Daten auf die Unternehmensstrategie (Mazzei und Noble 2017) oder auf gesellschaftliche Strukturen auf. Der traditionelle geschlossene Innovationsprozess hat sich durch das Konzept der Co-Creation in einen parallelen und offenen Prozess verwandelt (Guggenberger et al. 2020b). Zu diesem Zweck müssen die Innovationsaktivitäten gleichzeitig stattfinden, wobei Informationen aus verschiedenen Quellen verarbeitet und zeitgleich bereits die Produkte und Dienstleistungen konzipiert und gestaltet werden. Lineare Innovationsmodelle, bei denen die Aufgaben sequenziell abgearbeitet werden, sind daher ungeeignet für diesen Zweck (Wong et al. 2016). Diese neuen datengesteuerten Innovationen sind zunehmend schwieriger von einer einzelnen Organisation und in traditionellen Wertschöpfungsketten zu entwickeln. Stattdessen führt die zunehmend vernetzte Welt zur Kombination, Anreicherung und gemeinsamen Nutzung verschiedener Datenquellen von unterschiedlichen Akteuren in branchenübergreifenden, sozio-technischen Netzwerken – sogenannten Datenökosystemen (Gelhaar et al. 2021a; Oliveira und Lóscio 2018). Datenökosysteme bestehen aus komplexen Netzen von Organisationen und Einzelpersonen, die Daten als Hauptressource austauschen und nutzen (vgl. Abschnitt 1.3). Solche Ökosysteme bieten außerdem eine Möglichkeit und Basis für die Schaffung, Verwaltung und Aufrechterhaltung von Data-Sharing-Initiativen (Oliveira und Lóscio 2018). Der Wert der digitalen Transformation einer Gesellschaft und von Industrien ist unverkennbar. Jedoch muss der Wertschöpfungsprozess durchdacht und bewusst vollzogen werden (Mielli und Bulanda 2019).

Den Wert der Daten für Industrie und Gesellschaft betont auch die Bundesregierung in ihrer Datenstrategie¹, in der festgehalten ist, dass Daten die Grundlage der digitalen Gesellschaft bilden. Mit der Strategie will die Bundesregierung die

Die Europäische Union schätzt das globale Wachstum des verfügbaren Datenvolumens auf 175 Zettabytes für das Jahr 2025 (Europäische Kommission 2020b).

¹ <https://www.bundesregierung.de/breg-de/suche/datenstrategie-der-bundesregierung-1845632>.

innovative und verantwortungsvolle Datenbereitstellung und -nutzung insbesondere in Deutschland und Europa erhöhen. Eines der Ziele der Strategie ist es, deutsche und europäische Datenökosysteme für mehr Teilnehmer attraktiv zu machen, indem Dateninfrastrukturen interoperabel, energie- und ressourcensparend sowie dezentral ausgebaut werden. Dazu soll das branchenübergreifende Vorhaben Gaia-X (vgl. Abschnitt 1.2) vorangetrieben werden, um offene und transparente Datenökosysteme zu schaffen, in denen Daten und Dienste verfügbar gemacht, zusammengeführt und vertrauensvoll geteilt werden können (Bundeskanzleramt 2021).

Auch die Europäische Kommission hat in ihrer Datenstrategie Datenökosysteme und Data Sharing in den Fokus genommen. Laut der europäischen Datenstrategie² kann »die EU [...] zu einem Vorbild für eine Gesellschaft werden, die dank Daten in der Lage ist, in der Wirtschaft und im öffentlichen Sektor bessere Entscheidungen zu treffen« (Europäische Kommission 2020a, S. 1). Eines der Ziele der europäischen Datenstrategie ist es, einen einheitlichen europäischen Datenraum im Sinne eines Binnenmarktes für Daten zu schaffen. In diesem Datenökosystem sollen Daten sicher und leicht zur Verfügung stehen. Konkret besteht die Absicht, den Aufbau EU-weiter interoperabler Datenräume voranzutreiben, die die rechtlichen und technischen Hindernisse beseitigen sollen, die mit dem Data Sharing einhergehen können. In diesen Datenräumen sollen die europäischen Regelungen, insbesondere zum Schutz der Privatsphäre und zum Datenschutz, sowie das Wettbewerbsrecht in vollem Umfang eingehalten werden und die Regeln für den Zugang zu und die Nutzung von Daten fair, praktisch und klar sein (Europäische Kommission 2020b). Die Grundlage für die interoperablen Datenräume sollen dabei die föderierte Dateninfrastruktur von Gaia-X und der Standard für souveränen Datenaustausch der International Data Spaces Association

bilden, worauf jeweils in Abschnitt 1.2 nachfolgend eingegangen wird.

Die zunehmend durch die Digitalisierung generierten Daten und deren unternehmensübergreifender Austausch bieten viele Potenziale, welchen allerdings auch eine Reihe von Herausforderungen und Hemmnissen gegenüberstehen. Anreize für Unternehmen, Data Sharing zu betreiben und sich in dafür vorgesehenen Ökosystemen zu beteiligen, lassen sich somit zwar aus der Literatur ableiten, müssen aber auch noch aufgrund von Bedenken mit Hilfe von politischen Aktivitäten geschaffen werden. Im Rahmen des IEDS-Projekts sollen diese Anreize für Unternehmen aufgezeigt und darüber hinaus Anreizmechanismen und -systeme abgeleitet werden, über die Unternehmen dazu bewegt werden könnten, Data Sharing zu betreiben.

1.2 IDS und Gaia-X – Europäische Dateninfrastruktur als Basis des Data Sharings

Im Oktober 2015 initiierte die Fraunhofer-Gesellschaft das Forschungsprojekt **International Data Spaces (IDS)**³, gefördert durch das Bundesministerium für Bildung und Forschung (BMBF). Ziel der IDS-Initiative ist der Aufbau eines globalen Standards zum vertrauensvollen, sichereren, souveränen und interoperablen Datenaustausch. Dieses Bestreben wird von dem Anwenderverein International Data Spaces Association e. V. (IDSA)⁴ unterstützt. Im Jahr 2021 besteht der Verein aus über 130 Mitgliedern, die gemeinsam den IDS-Standard für Datensouveränität definieren. Die Mitglieder stammen dabei aus verschiedenen Domänen und erproben die IDS-Architektur in unterschiedlichsten Bereichen.

² https://ec.europa.eu/info/strategy/priorities-2019-2024/europe-fit-digital-age/european-data-strategy_de.

³ <https://internationaldataspaces.org/>.

⁴ <https://internationaldataspaces.org/we/the-association/>.

Im Herbst 2019 wurde außerdem die Initiative **Gaia-X**⁵ ins Leben gerufen, welche die Entwicklung einer nachhaltigen und innovativen Datenwirtschaft in Europa vorantreiben soll. Gaia-X zielt darauf ab, eine vereinigte Dateninfrastruktur zu schaffen, die auf europäischen Werten in Bezug auf Daten- und Cloud-Souveränität basiert (Gaia-X European Association for Data and Cloud AISBL 2021). Geografisch beschränkt sich Gaia-X dabei nicht auf Europa, sondern vertritt und stärkt europäische Werte für die Datenwirtschaft. Die Initiative steht in engem Zusammenhang mit der Europäischen Datenstrategie sowie mit dem EU-Konjunkturprogramm⁶. Dementsprechend unterstützt Gaia-X innovative Datenanwendungen und branchenübergreifende Innovationen. Durch die Berücksichtigung europäischer Werte ist Gaia-X als Schritt in Richtung digitaler Souveränität und technologischer Unabhängigkeit Europas anzusehen.

Eine Schlüsselfähigkeit für die europäische und internationale Wirtschaft ist in diesem Zusammenhang die Datensouveränität. Dateninhaber müssen dazu befähigt werden, gewünschte Datennutzer auszuwählen, Zwecke der Datennutzung zu limitieren und damit über die Verwertung ihrer Daten zu bestimmen. Dies erfordert entsprechende informationstechnische

Lösungen, um Datensouveränität zu ermöglichen und auszuüben.

Mit dem Ziel, Infrastrukturen für den unternehmensübergreifenden Datenaustausch zu fördern und dabei die Datensouveränität zu gewährleisten, verfügen beide Initiativen jeweils über zentrale Elemente. Eine wesentliche Komponente der IDS-Initiative stellen Konnektoren dar, über die sowohl Daten als auch dafür geltende Nutzungsbedingungen ausgetauscht bzw. festgelegt werden können (International Data Spaces Association 2019). Hier ist speziell der **Eclipse Dataspace Connector**⁷ aufzuführen. Dieser ermöglicht Unternehmen die Datenabfrage, den Datenaustausch und die technische Ausgestaltung sowie die Überwachung der Richtlinien, die für die beteiligten Parteien in den jeweiligen Szenarien gelten. Der Eclipse Dataspace Connector ist dabei erweiterbar und zur Verbindung mehrerer Cloud-Implementierungen sowie für den Einsatz in IDS- wie auch Gaia-X-Umgebungen geeignet. Konnektoren können demnach, wie in Abbildung 1.1 dargestellt, als eine sichere Möglichkeit zum Austausch von Daten in das gesamte Konzept von Gaia-X integriert werden. Die Konformität der IDS-Komponenten mit Gaia-X wird dabei im Referenzarchitekturmodell Version 4 (RAM 4.0) im Detail erläutert, welches im Frühjahr 2022 erscheinen wird.

5 <https://www.gaia-x.eu/what-is-gaia-x>.

6 https://europa.eu/next-generation-eu/index_de.

7 <https://projects.eclipse.org/proposals/eclipse-dataspace-connector>.

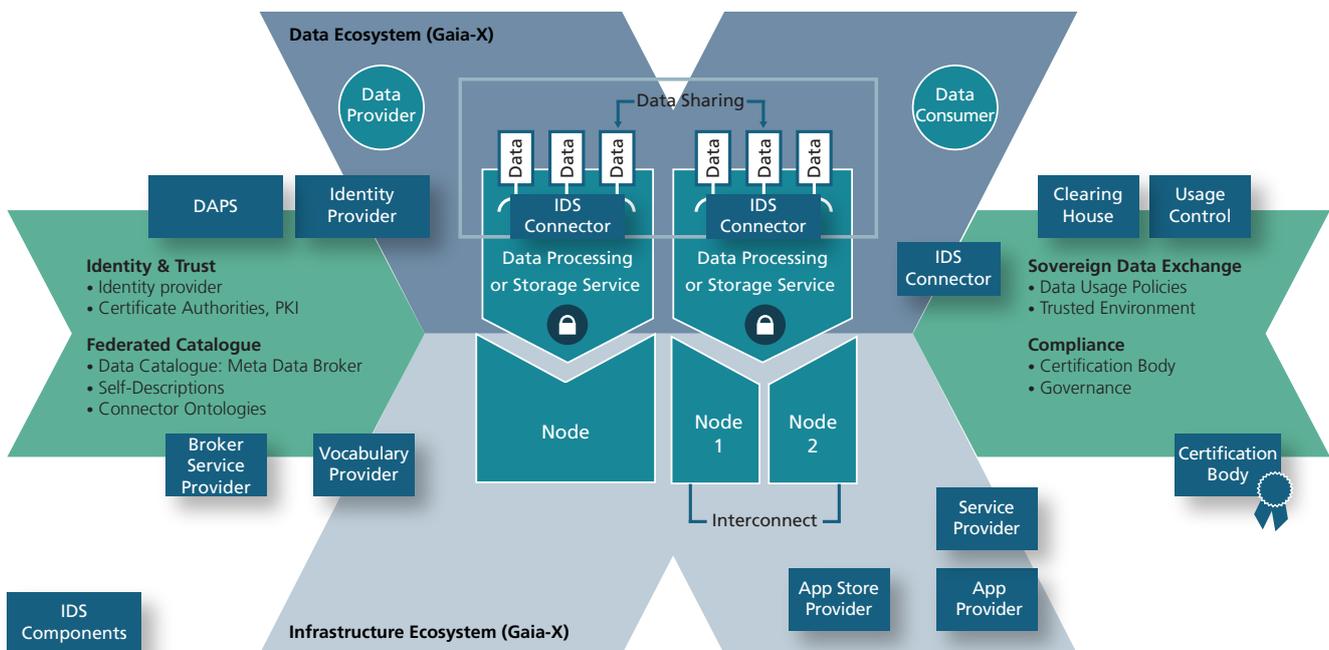


Abbildung 1.1: Integration und Zusammenspiel von IDS und Gaia-X (eigene Darstellung in Anlehnung an (Otto et al. 2021))



Darüber hinaus stimmen die zentralen Elemente von Gaia-X, die sog. **Federation Services**⁸, ebenfalls mit weiteren Komponenten aus den IDS überein. Die Gaia-X Federation Services »Identity & Trust«, »Federated Catalogue«, »Sovereign Data Exchange« und »Compliance« (vgl. Abbildung 1.1) stellen die technischen Mindestanforderungen und Dienste dar, die für den Betrieb föderierter Gaia-X-Ökosysteme aus Infrastruktur und Daten erforderlich sind. Dafür werden sie auf bestehende Standards und offene Technologien, wie zum Beispiel Open-Source-Software, zurückgreifen. Sie ermöglichen die vertrauensvolle Identifizierung von Teilnehmern und das Aufzeigen bestehender Daten- und Dienstleistungsangebote. Außerdem bieten sie Lösungen für den sicheren und transparenten Datenaustausch sowie die technische Überprüfung der Compliance von Akteuren und deren angebotenen Leistungen.

Durch die Federation Services ermöglicht Gaia-X den Zusammenschluss von Infrastrukturen, in denen verschiedene Akteure Daten und damit verbundene Ressourcen austauschen können.

Gaia-X und IDS weisen demnach ein hohes Potenzial dafür auf, sich gegenseitig zu ergänzen, um Cloud- und

Datensouveränität für durchgängige Datenwertschöpfungsketten in föderalen Ökosystemen zu gewährleisten. Dies wurde über die Grenzen der Gaia-X- und der IDS-Initiative hinaus erkannt, sodass sich diese im Rahmen der Data Spaces Business Alliance (DSBA)⁹ mit weiteren Teilnehmern zusammengeschlossen haben, um den Aufbau von Datenräumen sowie die Förderung der Datenwirtschaft als gemeinsame Ziele zu verfolgen (International Data Spaces Association 2021). Die Gaia-X-Architektur unterstützt und ermöglicht hierbei Datenräume zur Entwicklung fortschrittlicher intelligenter Dienste. Die IDS bieten dazu eine wesentliche und attraktive Ergänzung für Gaia-X, um den sicheren und souveränen Datenaustausch mittels Konnektoren zu gewährleisten. Gemeinsam tragen die IDS- und die Gaia-X-Initiative somit dazu bei, Barrieren zwischen Unternehmen abzubauen und komplexe Wertschöpfungsketten zu ermöglichen, in denen Daten ausgetauscht und verarbeitet werden können, um innovative Produkte und Dienstleistungen zu ermöglichen.

Vorhaben wie die der IDS- und der Gaia-X-Initiative schaffen Rahmenbedingungen für Unternehmen, um deren übergreifenden Datenaustausch zu fördern. Abschnitt 1.3 zeigt darüber hinaus weitere Bedingungen auf, unter denen Daten generiert und transferiert werden können.

⁸ <https://www.gxfs.de/federation-services/>.

⁹ <https://data-spaces-business-alliance.eu/>.

1.3 Data Sharing aus der unternehmensübergreifenden Perspektive

Durch die Einnahme einer unternehmensübergreifenden Perspektive mit Blick auf Data Sharing sollen Unternehmen in diesem Kapitel Faktoren und Möglichkeiten aufgezeigt werden, die im Allgemeinen gelten bzw. bestehen, wenn sie Daten teilen und austauschen oder dies zukünftig anstreben.

Europäische Initiativen, wie in Abschnitt 1.2 vorgestellt, zielen darauf ab, den souveränen Austausch von Daten zu gewährleisten und so Ökosysteme zu ermöglichen, in denen Unternehmen und weitere Akteure gemeinsam innovative und auf Daten basierende Produkte und Dienstleistungen entwickeln können. Um derartige Ökosysteme umfassend darzustellen und zu erläutern, wurde im Rahmen des IEDS-Projekts eine Darstellung entwickelt, die die verschiedenen und miteinander verknüpften Ökosystem-Typen sowie deren technische Bestandteile und Zusammenhänge präsentiert. Als Basis wurde hierbei auf die Vorarbeiten aus dem DEMAND Use Case Report (Azkan et al. 2020b) zurückgegriffen. Die in dieser Veröffentlichung dargestellten Building Blocks of Data Ecosystems wurden hierbei weiterentwickelt und auf Basis der Literatur wie u. a. Bansal und Kumar (2020); Oliveira und Lóscio (2018); Vargo et al. (2017) und der Betrachtung von Gaia-X-Anwendungsfällen näher spezifiziert. Dies hat zum Ziel, bei Unternehmen das Verständnis für derartige Ökosysteme zu entwickeln bzw. weiter zu schärfen und darüber hinaus Orientierungspunkte aufzuzeigen, wo und wie sie sich in den jeweiligen Ökosystemen beteiligen könnten. Hieraus resultieren die **Building Blocks of Ecosystems**, bestehend aus IoT (Internet of Things), Data und Service Ecosystems sowie deren jeweiligen Bestandteilen. Abbildung 1.2 zeigt die verschiedenen Ökosystem-Typen, in denen von der Datengenerierung über den Datenaustausch in Datenökosystemen bis zur Erstellung von innovativen, auf Daten basierenden Produkten und Dienstleistungen die gesamte Datenwertschöpfungskette betrachtet wird.

Data Generators

Abbildung 1.2 zeigt auf unterster Ebene den Building Block der Datengeneratoren. Sie sind die tatsächlichen Datenquellen in Form von technischen Komponenten und Systemen. Daten werden heute zunehmend am Rande von Netzwerken und durch die dort befindlichen Geräte erzeugt (Asch et al. 2018). Solche neuartigen Datenquellen umfassen hierbei Sensoren, die beispielsweise an physischen Objekten wie Maschinen, Fahrzeugen oder Verkehrsinfrastruktur angebracht sind und

darüber Daten in Netzwerke einspeisen. Sie werden dadurch zu Gegenständen des Internet of Things und damit zu wesentlichen Bestandteilen von IoT-Ökosystemen. Weitere Datenquellen stellen mobile Endgeräte, wie zum Beispiel Smartphones und Wearables, oder auch soziale Medien dar.

IoT Ecosystem

Der darauffolgende Building Block ist der der IoT-Ökosysteme. Die IoT-Ebene verbindet die reale Welt mit dem Internet. IoT-Ökosysteme umfassen große Mengen an miteinander verbundenen physischen Objekten und bilden ein System, in dem diese effizient verwaltet werden. Neben den physischen Geräten und den von ihnen produzierten Daten bestehen sie aus den Ressourcen, die die Vernetzung der echten mit der virtuellen Welt ermöglichen und fördern, wie unter anderem den dafür benötigten Hardware- und Software-Lösungen.

Im geschäftlichen Kontext stellen IoT-Ökosysteme eine Gemeinschaft interagierender Akteure wie Unternehmen oder Einzelpersonen dar, die eine gemeinsame Menge von Vermögenswerten und Ressourcen nutzen, um reale physische Objekte mit der virtuellen Welt des Internets zu verbinden (Mazhelis et al. 2012).

Data Assets

Darüber werden in Abbildung 1.2 die Datengüter als nächster Building Block aufgeführt. Diese wurden zuvor innerhalb der IoT-Ökosysteme durch die Datengeneratoren erzeugt. Sie repräsentieren die Bedingungen der Realität, geben virtuell Auskunft über die Zustände von physischen Objekten wie beispielsweise Maschinen und bilden die Basis für alle weiteren Aktivitäten sowie die Entwicklung innovativer Produkte und Dienstleistungen. Datengüter können zum Beispiel Maschinenbetriebsdaten, Positionsdaten oder Verkehrsdaten sein.

Actors and Roles

Über dem Building Block der Datengüter befindet sich der der Akteure und Rollen. Hierbei kann es sich um Unternehmen, Einzelpersonen oder auch Institutionen handeln. Sie können dabei eine oder mehrere Rollen einnehmen und erfüllen aufgrund ihrer jeweiligen Kompetenzen bestimmte Funktionen. Sämtliche Arten von Ökosystemen umfassen Akteure, die in diesen in ihren jeweiligen Rollen miteinander agieren. Auch in Datenökosystemen sind dies zentrale Bestandteile. Im Allgemeinen stellen Akteure dort Daten für andere bereit oder

nutzen selbst Datensätze, um darauf aufbauend wertschöpfende Aktivitäten durchzuführen.

Data Ecosystem

Die Datenökosysteme sind dabei der nächste Building Block. Ein Datenökosystem ist ein Netzwerk, in dem die Akteure ihre geschäftlichen Beziehungen und Interaktionen auf Daten basieren und die an vorheriger Stelle generierten Datengüter unternehmensübergreifend austauschen. Datenökosysteme umfassen dabei sämtliche Interessengruppen in Form von Akteuren und Rollen und verbinden diese direkt oder indirekt innerhalb des Netzwerks und der existierenden Wertschöpfungsketten (Koskinen et al. 2019). Dadurch betreiben sie gemeinsame Wertschöpfung, von der alle beteiligten Akteure letztlich profitieren können. Der Umgang der Akteure mit Daten geschieht hierbei in einer Datenwertschöpfungskette, welche in Abbildung 1.2 am linken Rand abgebildet ist. Diese lässt sich in fünf Stufen einteilen, auf denen die beteiligten Akteure aktiv sein können. Dabei handelt es sich allerdings nicht zwingend um einen linearen Prozess, da auf den jeweiligen Stufen möglicherweise mehrere Schleifen durchlaufen werden. Die Datenwertschöpfungskette beginnt mit der Generierung der Daten (1), bevor diese anschließend vorverarbeitet und zur Erhöhung der Datenqualität kuratiert werden (2). Zur Gewinnung von Informationen aus den Daten werden diese anschließend analysiert (3) und im weiteren Verlauf mit weiteren Informationen und Erfahrungswerten aus zusätzlichen Branchen und Domänen kombiniert (4). Das daraus resultierende Wissen kann nun auf vorhandene Problemstellungen angewandt und zur Entscheidungsfindung im geschäftlichen Kontext genutzt werden (5).

Datenökosysteme und die Datenwirtschaft weisen einen direkten Zusammenhang auf. Jedes Datenökosystem stellt hierbei einen Teil der Datenwirtschaft dar (Koskinen et al. 2019).

Data-driven Services

Der auf den Datenökosystemen aufbauende Building Block sind die datengetriebenen Services. Sie resultieren aus der Interaktion der verschiedenen Akteure über mehrere Ökosysteme hinweg, dem dabei durchgeführten Datenaustausch sowie dem Durchlaufen der Datenwertschöpfungskette und stellen innovative und datengetriebene Dienstleistungen dar (Azkan et al. 2021). Bei datengetriebenen Services werden

die zuvor generierten und weiterverarbeiteten Datengüter als zentrale Ressource genutzt. Diese datengetriebenen Dienstleistungen zielen darauf ab, die Entscheidungsfindung im strategischen betriebswirtschaftlichen Kontext zu unterstützen. Der zugrunde liegende Wertschöpfungsprozess zur Erstellung der datengetriebenen Services kann dabei in Kern- und Stützprozesse unterteilt werden, welche die Entwicklung von datengetriebenen Services realisieren bzw. unterstützen, wie beispielsweise die Analyse von Daten oder die Bereitstellung der benötigten technischen Infrastruktur. Durch den unternehmensübergreifenden Austausch von Daten werden die Interaktion von Akteuren und die Integration ihrer Ressourcen innerhalb eines Ökosystems ermöglicht. Durch diese sog. Value Co-Creation werden datengetriebene Services erstellt, durch die jeder Akteur profitiert. Diese Art von Dienstleistungen ist dabei zentraler Bestandteil von Service-Ökosystemen.

In Service-Ökosystemen integrieren die Akteure ihre Ressourcen und sind durch die gegenseitige Wertschöpfung und den Austausch von Dienstleistungen miteinander verbunden (Lusch und Vargo 2014).

Service Ecosystem

Auf der obersten Ebene der Building Blocks sind die Service-Ökosysteme. Wie in den anderen Ökosystem-Typen schaffen Akteure auch in Service-Ökosystemen gegenseitig Werte. Dies geschieht in Service-Ökosystemen im Speziellen durch den Fokus auf Prozesse und Ergebnisse, die durch ihre Interaktionen bereitgestellt bzw. erreicht werden sollen. Zu diesem Zweck wenden sie ihre jeweiligen Kompetenzen in Form von Wissen oder Fähigkeiten an und verhalfen sich so gegenseitig zu Vorteilen. Dies geschieht in Service-Ökosystemen durch die gemeinsame Nutzung von Ressourcen und den Austausch der datengetriebenen Dienstleistungen, welche zuvor auf Basis der generierten Daten und durch die Interaktion im Rahmen der vorgestellten Building Blocks sowie entlang der Datenwertschöpfungskette entwickelt wurden.

Die hier vorgestellten Building Blocks of Ecosystems stellen in Abbildung 1.2 die allgemeinen Rahmenbedingungen in Bezug auf Data Sharing dar. Im Anschluss werden in Abschnitt 1.4 auch die Anforderungen erläutert, die Unternehmen intern adressieren müssen, wenn sie über ihre Grenzen hinaus Daten austauschen möchten.

BUILDING BLOCKS OF ECOSYSTEMS

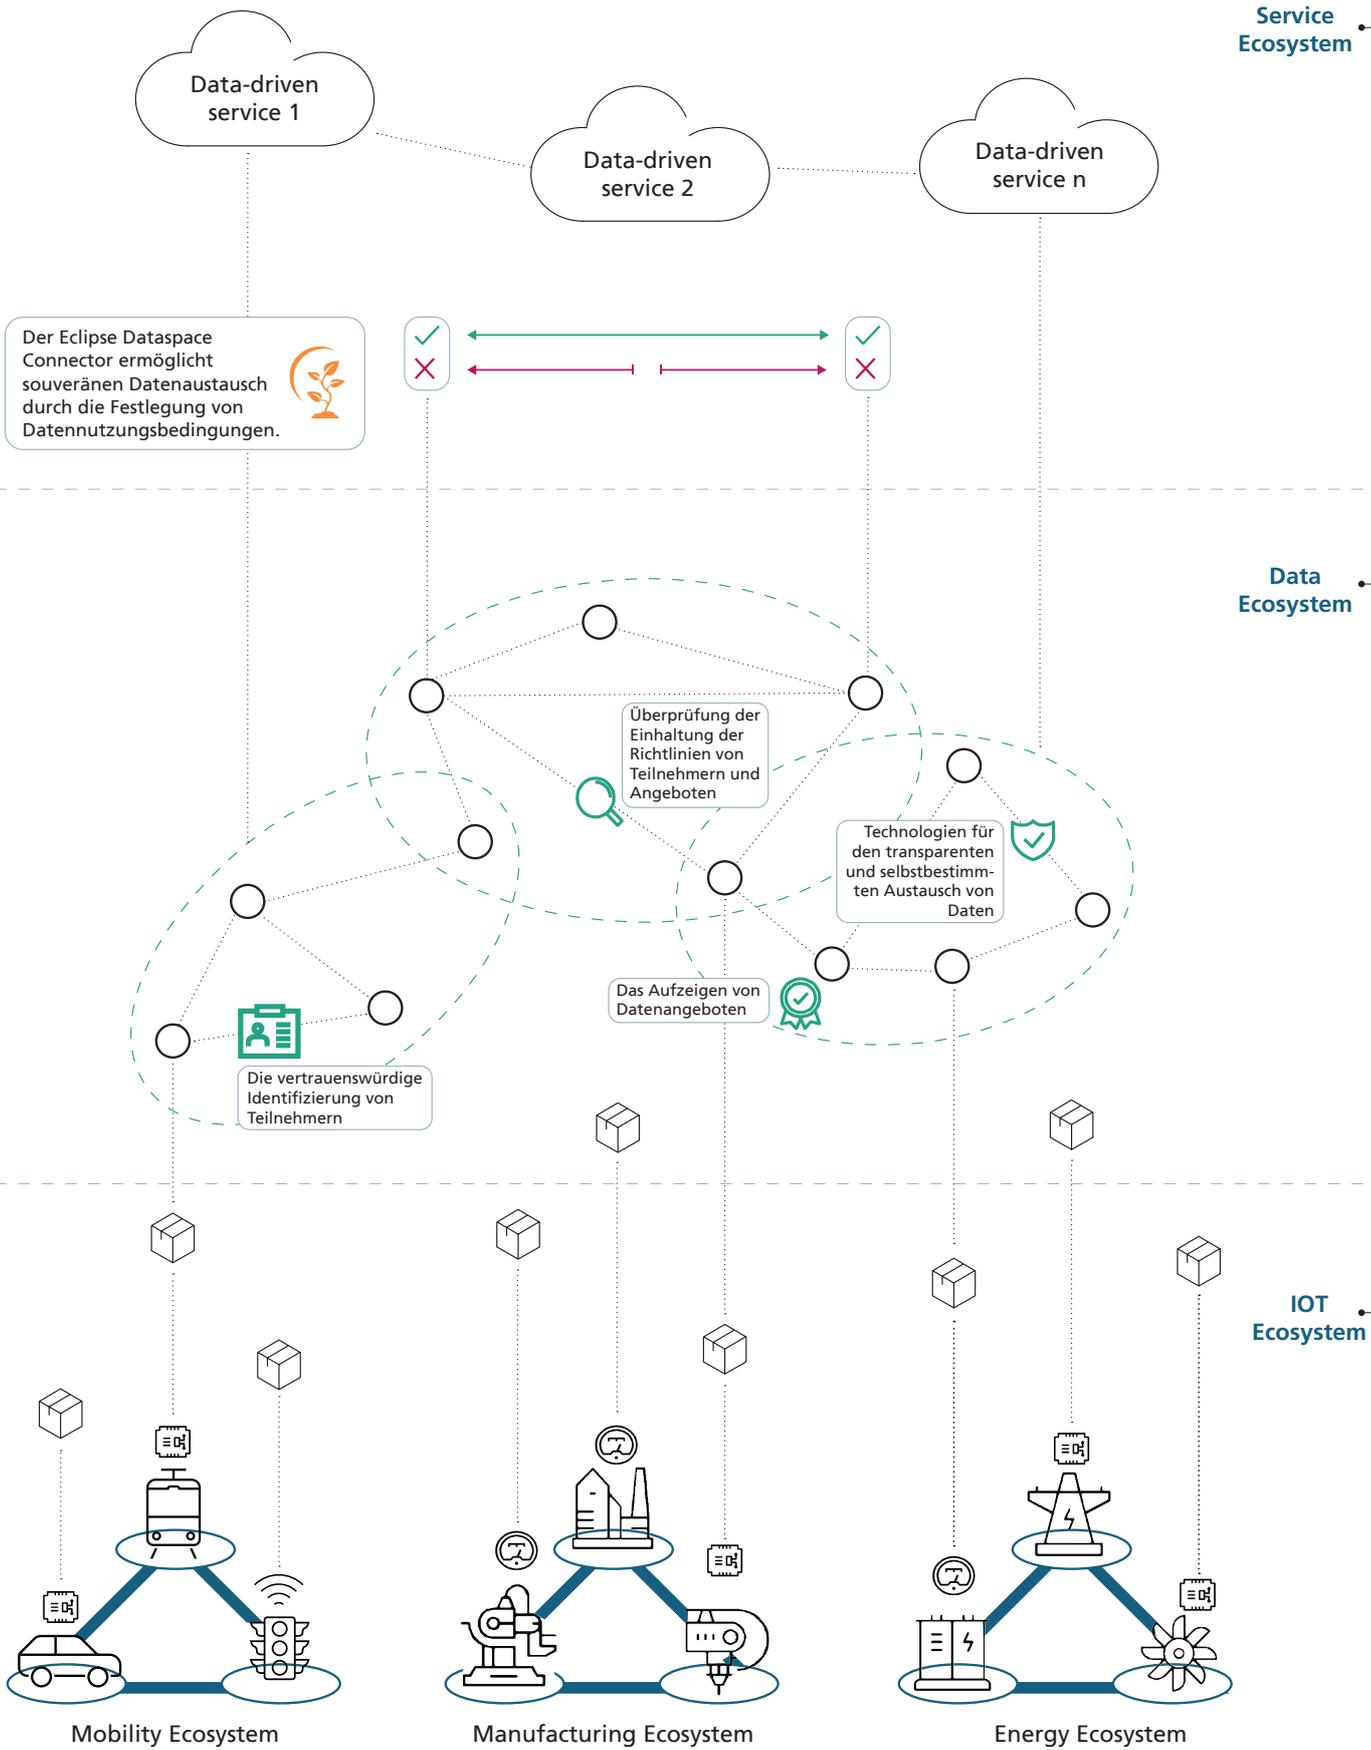


Abbildung 1.2: Building Blocks of Ecosystems unternehmensexterne Perspektive auf Data Sharing (eigene Darstellung in Anlehnung an (Azkan et al. 2020b))

SERVICE ECOSYSTEM

In Dienstleistungs-Ökosystemen integrieren Akteure ihre Ressourcen. Durch gemeinsame Vereinbarungen sowie den Austausch von Dienstleistungen schaffen sie gemeinsam und gegenseitig Werte.



DATA-DRIVEN SERVICES

Datengetriebene Dienstleistungen stellen Lösungen dar, die auf weiterverarbeiteten Daten basieren. Sie sind sowohl Resultat als auch Ziel der gemeinsamen Wertschöpfung mehrerer Akteure in Datenökosystemen.



DATA ECOSYSTEM

Innerhalb von Datenökosystemen stellen Daten die zentralen Ressourcen dar. Auf ihnen basieren somit auch die geschäftlichen Beziehungen und Interaktionen der Akteure.



ACTORS AND ROLES

Verschiedene Akteure, bei denen es sich sowohl um Individuen als auch um Unternehmen handeln kann, agieren in Ökosystemen. Diese übernehmen dabei eine oder mehrere Rollen, in denen sie zum Beispiel Daten bereitstellen, vermitteln oder konsumieren.



DATA ASSETS

Generierte Daten, die im weiteren Verlauf für die Erstellung von datenbasierten Dienstleistungen verwendet werden, stellen Data Assets dar. Hierbei handelt es sich unter anderem um Fahrzeug- oder Maschinenbetriebsdaten.



IOT ECOSYSTEM

Geräte des Internet of Things sind die wesentlichen Bestandteile von IoT-Ökosystemen. Dabei handelt es sich um mit Sensoren ausgestattete physische Objekte, über die Daten erzeugt und an anderer Stelle bereitgestellt, konsumiert und weiterverarbeitet werden.



DATA GENERATORS

Sie stellen die Quellen der Daten dar. Immer mehr Daten werden am Rande von Netzwerken durch die dort befindlichen Geräte erzeugt. Dabei handelt es sich zum Beispiel um IoT-Geräte und eine Vielzahl von an physischen Objekten installierten Sensoren.



1.4 Data Sharing aus der unternehmensinternen Perspektive

Damit Unternehmen in der Lage sind, durch unternehmensübergreifenden Datenaustausch wertschöpfende Aktivitäten zu betreiben, ist es notwendig, dass Unternehmen, die an einem Ökosystem partizipieren wollen, verschiedene interne Handlungsfelder betrachten (hier unternehmensinterne Perspektive). Dazu wurde im IEDS-Projekt ein dreischichtiges Rahmenmodell (vgl. Abbildung 1.3) entworfen, welches aus der Strategie-, Prozess- und Systemebene besteht. Dieses Modell stellt die Basis für die Erarbeitung von Anreizen dar, wodurch Unternehmen dazu bewegt werden sollen, am Data Sharing zu partizipieren. Durch die strukturierte Darstellung der wesentlichen Handlungsfelder unterstützt das Modell die Transformation von Unternehmen. Auf der Grundlage dieses Modells lassen sich unternehmensinterne Anreize herausarbeiten, mit deren Hilfe das Teilen von Daten gefördert wird.

Strategieebene

Die Strategieebene stellt die oberste Ebene dieses Rahmenmodells dar und wird von der Geschäftsführung des Unternehmens herausgearbeitet. Auf dieser Ebene werden mittelfristige Entscheidungen mit einem Zeithorizont von ein bis drei Jahren definiert. Dabei wird der strategische Umgang mit Daten im Unternehmen sowie der Umgang und Austausch von Daten mit anderen Unternehmen festgelegt. Auf strategischer Ebene wird ferner zwischen datengetriebenen Geschäftsmodellen und der Datenstrategie unterschieden. Geschäftsmodelle werden auf Grundlage von strategischen Entscheidungen entwickelt, welche die Leistungsversprechen des jeweiligen Unternehmens erweitern bzw. ergänzen. Dafür ist jedoch zunächst eine Datenstrategie notwendig, um darauf aufbauend die datengetriebenen Geschäftsmodelle zu entwickeln und die Prozesse im Unternehmen dahingehend anzupassen.

Datengetriebene Geschäftsmodelle (vgl. Abschnitt 3.3): Aufgrund der zunehmenden Vernetzung von Unternehmen wird die Grundlage für neuartige Geschäftsmodelle auf Basis von Daten geschaffen. In der Literatur werden diese als unternehmerische Konzepte der Geschäftsaktivität beschrieben, welche Daten als Schlüsselressource für Geschäftsaktivitäten nutzen und Aktivitäten darauf aufbauen (Azkan et al. 2020a; Hartmann et al. 2016). Sie bieten neue Gelegenheiten zur Schaffung neuer Wertströme in Form von Geschäftsmodellen, sowohl im B2B- als auch im B2C-Umfeld.

Datenstrategie (vgl. Abschnitt 3.2):

Die Datenstrategie eines Unternehmens beschreibt eine Reihe von Kernaspekten in Bezug auf defensive und offensive Handlungen im Umgang mit Daten. Im defensiven Fall handelt es sich um Datensicherheit, Integrität, Qualität, Einhaltung von Vorschriften und Governance. Im Unterschied dazu beinhalten offensive Handlungen eine Verbesserung der eigenen Position im Wettbewerb und die Steigerung der Profitabilität (DalleMule und Davenport 2017). Bei der Teilnahme an Ökosystemen liegt der Fokus insbesondere auf den offensiven Bestandteilen der Datenstrategie. Es werden dabei Anreize des Datenaustauschs und der damit verbundenen Schaffung von datengetriebenen Geschäftsmodellen beleuchtet. Initial stellt damit die Datenstrategie die Grundlage für datengetriebene Geschäftsmodelle dar. In der Folge besteht ein gegenseitiger Einfluss, wobei die Datenstrategie die Grundzüge datengetriebener Geschäftsmodelle orchestriert und Entwicklungen datengetriebener Geschäftsmodelle in Bezug auf Nachfrage bzw. geänderte Nachfrage die Datenstrategie des Unternehmens beeinflussen.

Prozessebene

Die Prozessebene beschreibt die gegenwärtige Verwaltung und Bewertung der unternehmenseigenen Daten. Diese Ebene wird unterteilt in Data Governance, Datenmanagement, Datenbewertung und Datenanalyse. Der Fokus liegt im durchgeführten



Data Sharing aus der unternehmensinternen Perspektive

■ Kernthema
■ im Fokus für das IEDS-Projekt
■ nicht im Fokus

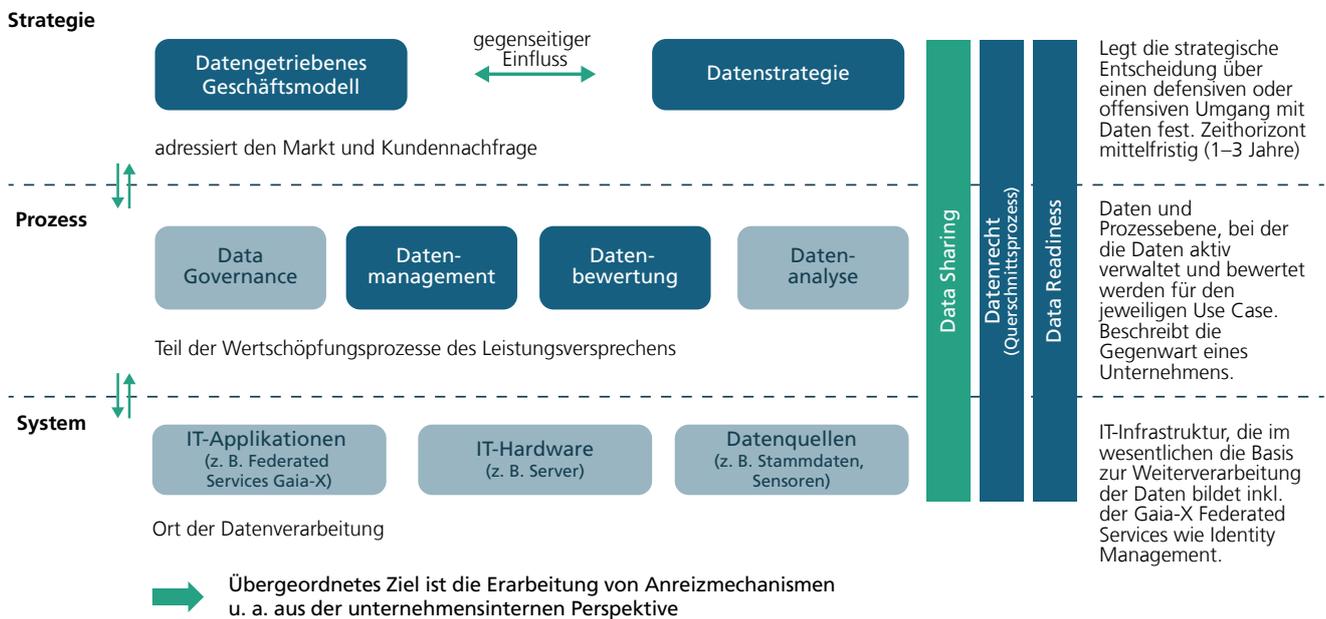


Abbildung 1.3: Data Sharing aus der unternehmensinternen Perspektive und Projektfokus (eigene Darstellung)

Projekt auf dem Bereich des Datenmanagements und der Datenbewertung.

Data Governance:

Data Governance stellt den Rahmen für das Datenmanagement im Unternehmen dar. Hierbei werden Rollen und Zuständigkeiten in Bezug auf das Management von Daten festgelegt. Damit wird eine Grundlage für die Verarbeitung, Speicherung, Pflege und Darstellung der Daten generiert (Otto und Österle 2016).

Datenmanagement (vgl. Abschnitt 3.2):

Datenmanagement befasst sich mit der Entwicklung, Ausführung und Überwachung von Plänen, Richtlinien, Programmen und Praktiken, die den Wert von Daten und Informationsbeständen während ihres gesamten Lebenszyklus bereitstellen, kontrollieren, schützen und steigern. Die Funktion des Datenmanagements unterliegt dabei dem Ordnungsrahmen der Data Governance und damit dem Lebenszyklusmanagement von Daten, von der Planung und dem Design über die Verwaltung sowie Aufwertung der Daten bis zur Datennutzung und Pflege (Henderson und Earley 2017).

Datenbewertung (vgl. Abschnitt 3.4):

Datenbewertung stellt einen weiteren Kernaspekt im dreischichtigen Rahmenmodell im Hinblick auf die Anreize zum Datenaustausch dar. Hierbei werden Daten im Unternehmen hinsichtlich ihrer Qualität, ihrer Prozesse, ihrer Performance, ihrer Kosten, ihres Nutzens und ihrer Marktwerte betrachtet.

Im Rahmen des Datenaustauschs mit anderen Unternehmen ist für die Bewertung der Daten auf der finanziellen Ebene aktuell die Bestimmung des Marktwerts die gängigste Methode (Krotova et al. 2019).

Datenanalyse:

Bei der Datenanalyse werden qualitative und quantitative Daten im Rahmen verschiedener Analysemöglichkeiten verwendet, um daraus Erkenntnisse für die eigenen Prozesse, aber auch für externe Abläufe zu gewinnen. Zu den verschiedenen Datenanalysemöglichkeiten zählen unter anderem deskriptive, prädiktive bzw. präskriptive Analysen, welche je nach Komplexität Aussagen über mögliche zukünftig eintretende Ereignisse treffen können (Hupperz et al. 2021). Für ein Unternehmen leitet sich daraus ein Anreiz ab, in die Analyse eigener Daten zu investieren. Darüber hinaus können die Ergebnisse potenziell neben der eigenen Verwertung auch gewinnbringend veräußert werden.

Systemebene

Bei der untersten Ebene des Rahmenmodells handelt es sich um die Systemebene, welche durch Anwendungssoftware, IT-Hardware und Datenquellen, die hinter den Prozessen liegen, gebildet wird. Diese legen den technischen Grundstein für den Datenaustausch, stehen jedoch nicht im Fokus des IEDS-Projekts, werden aber dennoch zur vollständigen Darstellung erwähnt.

IT-Applikationen:

Anwendungssoftware, wie z. B. das Identity Management der Gaia-X Federation Services, bildet die Grundlage für den Austausch von Daten innerhalb des Gaia-X-Ökosystems. Das Identity Management ist ein Baustein der technischen Mindestanforderungen und Dienste für den Betrieb des föderierten Gaia-X-Ökosystems (GAIA-X 2021).

IT-Hardware:

Um Daten speichern, verarbeiten und letztendlich auch teilen zu können, benötigen die Unternehmen zunächst IT-Hardware, um beispielsweise die Speicherung von Daten On-Premise oder in einer Public Cloud zu ermöglichen.

Datenquellen:

Damit Daten im ersten Schritt überhaupt generiert werden können, müssen zunächst Datenquellen bzw. -generatoren und relevante Datensätze identifiziert werden. Dies betrifft Stammdaten, Metadaten, aber auch z. B. Sensoren, die Daten im Produktions- oder Logistikprozess generieren.

Querschnittsthemen

Darüber hinaus gibt es im Rahmenmodell drei Querschnittsthemen, deren Inhalte übergreifend betrachtet werden müssen. Dabei handelt es sich um Data Sharing, Datenrecht und Data Readiness.

Data Sharing (vgl. Abschnitt 3.1):

Das Data Sharing umfasst alle Aspekte des in Abbildung 1.3 dargestellten Modells, von der Datenstrategie, die den Datenaustausch als Ziel festlegt, über die Datenflussverfahren bis hin zur technischen Ausführung auf Systemebene. Das bedeutet, dass die Abläufe im Unternehmen über alle Modellebenen

hinweg auf das Ziel des Datenaustauschs ausgerichtet werden müssen, damit ein solcher auf technischer Ebene und in Einklang mit der Datenstrategie des Unternehmens überhaupt erfolgen kann. Beim Data Sharing wird zwischen dem unternehmensinternen Datenaustausch und dem Datenaustausch mit externen Unternehmen unterschieden.

Datenrecht (vgl. Abschnitt 3.5):

Im Prozess der Entwicklung datengetriebener Geschäftsmodelle, des Wertschöpfungsprozesses und der Datenverarbeitung ist stets das Datenrecht zu berücksichtigen. Dabei ist sowohl bei der Definition der Datenstrategie als auch bei der Entwicklung des datengetriebenen Geschäftsmodells im ersten Schritt bereits eine Machbarkeit unter Berücksichtigung von Regularien wie zum Beispiel der DSGVO im Bereich Datenaustausch zu evaluieren. Dies betrifft zudem die Prozess- und die Systemebene, wo der Umgang mit den entsprechenden Daten im Sinne des Datenrechts erfolgen muss (Pandit et al. 2018). Des Weiteren sind auch bevorstehende rechtliche Vorgaben, wie der Data Act der EU, im Prozess zu berücksichtigen (Europäische Kommission 2021).

Data Readiness (vgl. Abschnitt 2.1):

Data Readiness, oder auch Data Economy Readiness, beschreibt die Fähigkeit eines Unternehmens, Daten zu verarbeiten und zu nutzen. Diese Fähigkeit wird auch Reifegrad der Datenbewirtschaftung genannt. Die Arten der Daten, die Unternehmen speichern, spielen dabei ebenso eine Rolle wie die umgesetzten Formen des Datenmanagements und die Zwecke, zu denen das Unternehmen Daten nutzt.

Der aktuelle Status zum Data Sharing von Unternehmen und zu deren Fähigkeiten, an der Datenwirtschaft teilzunehmen, wird im folgenden Kapitel 2 genauer thematisiert.



2 Status Quo der gemeinsamen Datenbewirtschaftung in Deutschland

Im Folgenden wird der Status quo des Data Sharings und der Datenwirtschaft in Deutschland beleuchtet. Dazu wird zunächst geprüft, ob Unternehmen die Voraussetzungen erfüllen, um Daten zu teilen und gemeinsam mit anderen Unternehmen zu bewirtschaften (vgl. Kapitel 2.1). Da die Gaia-X-Initiative eine Infrastruktur entwickelt, um die gemeinsame Datenbewirtschaftung von Unternehmen zu ermöglichen, werden in Kapitel 2.2 Maßnahmen zur Analyse der Reichweite und Akzeptanz der Initiative dargestellt.

2.1 Data Economy Readiness und gemeinsame Datenbewirtschaftung

Unternehmen müssen bestimmte Voraussetzungen erfüllen, um Daten gemeinsam mit anderen Unternehmen zu bewirtschaften. Zum einen müssen sie technisch und organisatorisch in der Lage sein, Daten effizient zu bewirtschaften. Zum anderen müssen sie aber auch bereit und willens sein, eigene Daten an Externe weiterzugeben oder Daten anderer Unternehmen zu verwenden. Die sogenannte Data Economy Readiness ist eine Voraussetzung, um an Gaia-X (vgl. Kapitel 1.2) partizipieren zu können.

Im Projektteil Data Economy Readiness wird mittels einer repräsentativen Umfrage unter 1.002 Unternehmen aus den Bereichen Industrie und industrienaher Dienstleister (Befragungszeitraum September bis November 2021) geprüft, inwiefern Unternehmen in Deutschland in der Lage sind, Daten effizient zu bewirtschaften. Neben der eigenen Data Economy Readiness wird erfragt, inwiefern die gemeinsame

Datenbewirtschaftung mit anderen Unternehmen eine Rolle spielt. Um zu ermitteln, für wie viele Unternehmen der Aufbau einer souveränen und sicheren Cloud-Infrastruktur eine Relevanz hat, werden die Unternehmen auch zu ihrem Cloud-Nutzungsverhalten befragt.

Insbesondere kann der Anteil der Unternehmen identifiziert werden, der zwar die Voraussetzungen zur Teilnahme an der Datenwirtschaft erfüllt und unter Umständen auch eine unternehmensinterne Datenbewirtschaftung betreibt, bislang jedoch keine Daten mit anderen Unternehmen gemeinsam nutzt. Eventuelle Hemmnisse können so identifiziert werden.

Kernergebnisse der Umfrage:

Aufbauend auf und anschlussfähig an bestehende Reifegradhebungen (Röhl et al. 2021; Demary et al. 2019) wird ermittelt, inwieweit Unternehmen data economy ready sind oder nicht, also in der Lage sind, ihre Daten effizient zu bewirtschaften. Dafür ist das Antwortverhalten der Unternehmen zu folgenden drei Aspekten der Datenbewirtschaftung relevant:

- Datenspeicherung
- Datenmanagement
- Datennutzung

Beim Aspekt der Datenspeicherung wird erfragt, welche Arten von Daten Unternehmen in digitaler Form speichern. Dazu zählen beispielsweise Produkt-, Prozess- oder Personaldaten, die eher die unternehmenseigene Produktion oder Belegschaft betreffen sowie Lieferantentendaten oder Nutzungsdaten

von Kunden, die sich auf Unternehmenspartner oder Akteure außerhalb des Unternehmens beziehen.

Beim Aspekt des Datenmanagements wird geprüft, wie Unternehmen mit ihren Daten umgehen. Es wird beispielsweise erfragt, ob die unternehmensinterne Datenweitergabe über standardisierte und permanente Schnittstellen erfolgt, ob eine Klassifizierung und Qualitätsprüfung der Daten durchgeführt wird oder ob Unternehmen regelmäßig nach neuen Datenquellen und Möglichkeiten der Datennutzung suchen.

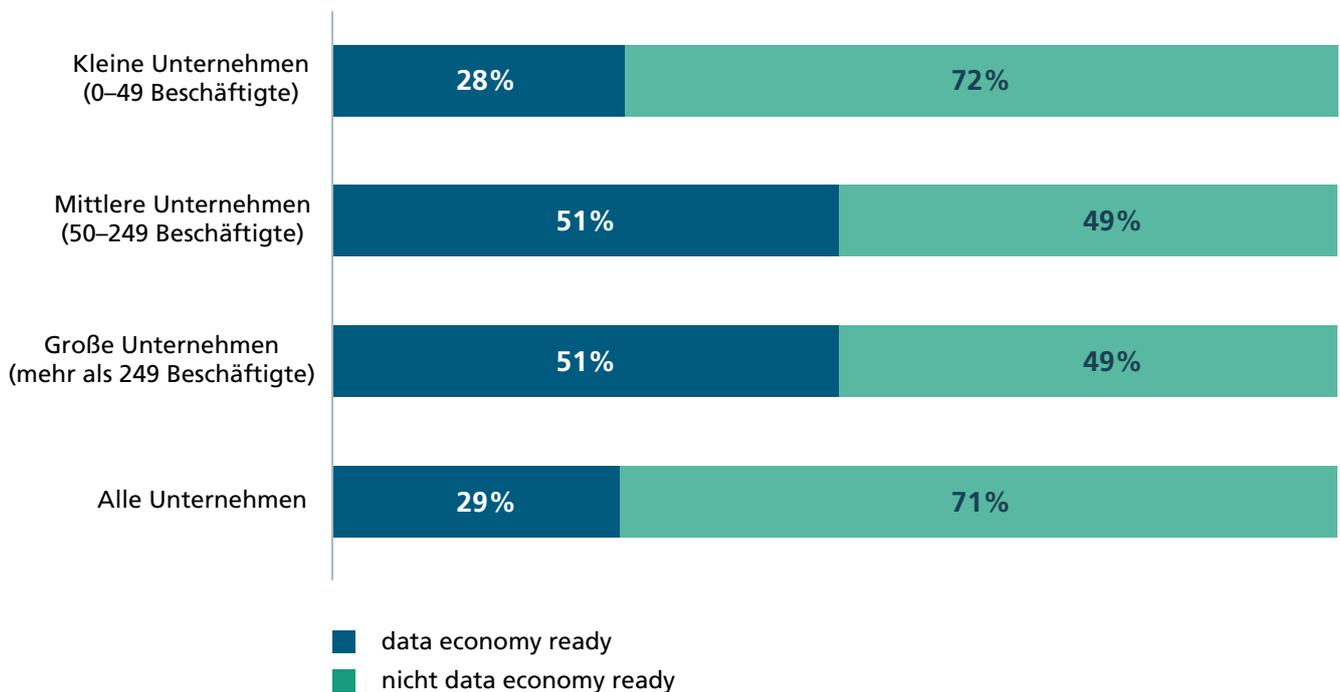
Beim Aspekt der Datennutzung wird ermittelt, zu welchen Zwecken Unternehmen Daten verwenden. Zu den abgefragten Zwecken zählen die (Weiter-)Entwicklung von Produkten, Dienstleistungen oder Geschäftsmodellen. Außerdem können

Daten zur Automatisierung und Steuerung verwendet oder zum direkten oder indirekten Verkauf angeboten werden.

Basierend auf dem Antwortverhalten werden die Unternehmen in die Gruppen data economy ready oder nicht data economy ready eingeteilt. Abbildung 2.1 zeigt die Ergebnisse.

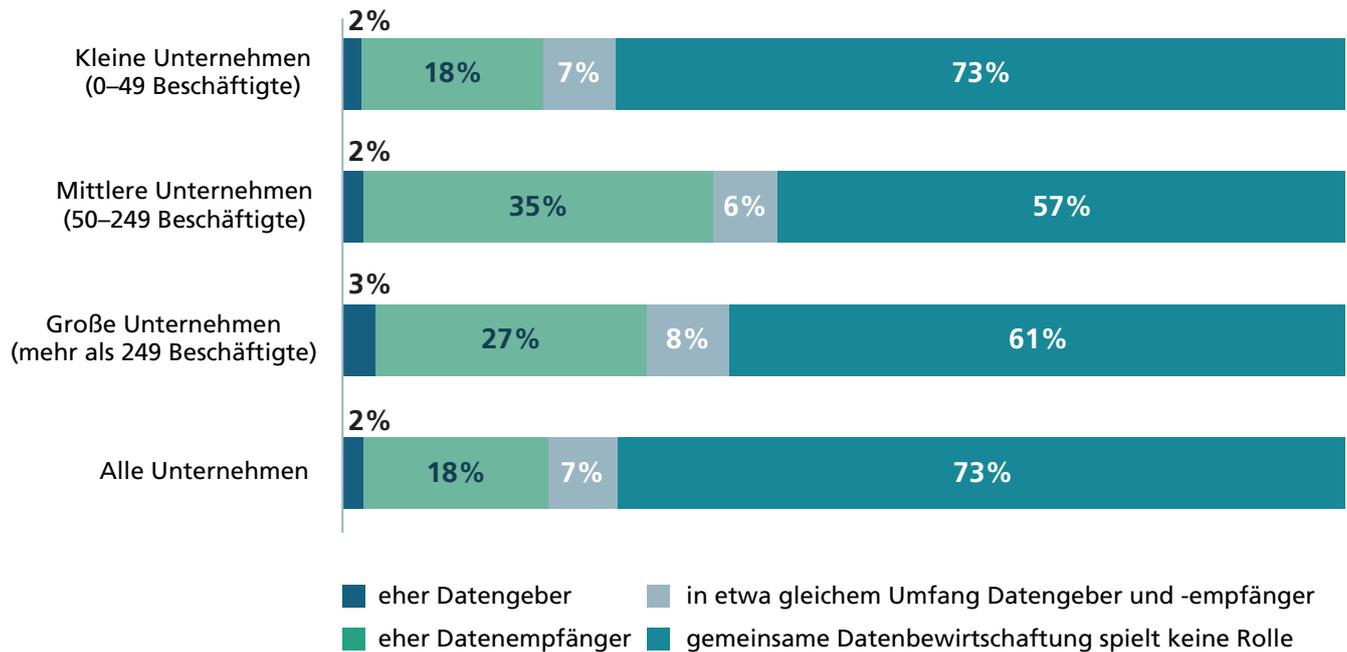
29 Prozent aller befragten Unternehmen sind data economy ready. Die große Mehrheit von 71 Prozent ist nicht data economy ready, kann ihre Daten also nicht effizient bewirtschaften.

Mittlere und größere Unternehmen schneiden besser ab als kleine. Etwa die Hälfte dieser Unternehmen mit mindestens 50 Beschäftigten ist data economy ready. Bei den kleinen Unternehmen mit bis zu 49 Beschäftigten sind es 28 Prozent.



Anteil der Unternehmen; n = 1.002; Befragungszeitraum September bis November 2021

Abbildung 2.1: Data economy readiness (Institut der deutschen Wirtschaft)



Anteil der Unternehmen; n = 987; Befragungszeitraum September bis November 2021

Abbildung 2.2: Datenteilung (Institut der deutschen Wirtschaft)

In einem zweiten Schritt werden die Unternehmen danach befragt, ob Datenteilung für sie eine Rolle spielt und ob sie dabei eher Datengeber oder Datenempfänger (vgl. Abbildung 2.2).

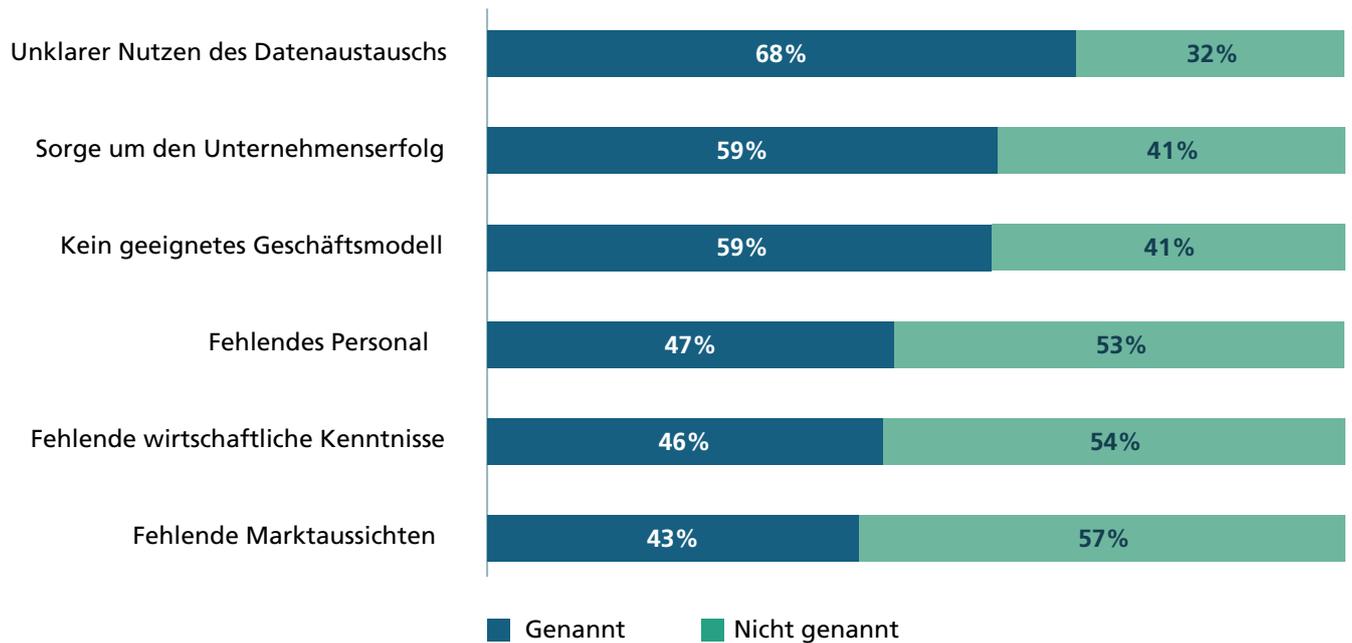
Für 73 Prozent aller Unternehmen spielt die gemeinsame Datenbewirtschaftung keine Rolle. 18 Prozent der Unternehmen sind eher Datenempfänger, zwei Prozent eher Datengeber und sieben Prozent in etwa gleichem Umfang Datengeber und Datenempfänger.

Das Abschneiden der kleinen Unternehmen mit weniger als 50 Beschäftigten liegt wie auch schon der Data Economy Readiness nah am gesamtdeutschen Ergebnis. Dies ist der Tatsache geschuldet, dass die Unternehmensgrößenstruktur in Deutschland durch sehr viele kleine Unternehmen geprägt ist (Destatis 2020).

Mit 43 Prozent ist der Anteil der Unternehmen, für die die gemeinsame Datenbewirtschaftung eine Rolle spielt, bei

mittleren Unternehmen am höchsten, noch vor großen Unternehmen mit 38 Prozent. Dieses Ergebnis ist insofern überraschend, als dass der Anteil der Unternehmen, die data economy ready sind, bei beiden Größenklassen gleich ist. Die im Vergleich zu den großen Unternehmen höhere Relevanz der gemeinsamen Datenbewirtschaftung bei den mittleren Unternehmen liegt vor allem an dem mit 35 Prozent deutlich höheren Anteil der Datenempfänger (große Unternehmen: 27 Prozent). Mittlere Unternehmen sind somit häufiger offen für die Nutzung von externen Daten. Eine Erklärung könnte sein, dass mittlere Unternehmen häufiger abhängig von externen Partnern und somit eher auf externe Daten angewiesen sind. Dafür weisen große Unternehmen leicht höhere Anteile bei Datengebern sowie bei der Antwort »in etwa gleichem Umfang Datengeber und Datenempfänger« auf.

Insgesamt sieht sich ein Großteil aller Unternehmen eher als Empfänger von Daten, die Dritte bereitstellen. Lediglich zwei Prozent sind eher Datengeber. Die Weitergabe eigener Daten spielt bei den befragten Unternehmen eine sehr geringe Rolle.



Anteil der Unternehmen, die wirtschaftliche Hemmnisse hinsichtlich des Teilens von Daten wahrnehmen; n = 219; Befragungszeitraum September bis November 2021

Abbildung 2.3: Wirtschaftliche Hemmnisse des Datenteilens (Institut der deutschen Wirtschaft)

Dies deutet auf Hemmnisse des Datenteilens hin, die vermutlich eher bei der Datenweitergabe als bei der Datennutzung von Dritten vorliegen. Konkret nennen die Unternehmen folgende wirtschaftliche Hemmnisse im Zusammenhang mit dem Datenteilen (Abbildung 2.3).

68 Prozent aller Unternehmen, die wirtschaftliche Hemmnisse wahrnehmen, geben den unklaren Nutzen des Datenaustauschs als wirtschaftliches Hemmnis an. Jeweils 59 Prozent der Unternehmen nennen die Sorge um den eigenen Unternehmenserfolg oder das Fehlen eines geeigneten Geschäftsmodells. Weitere wirtschaftliche Hemmnisse sind fehlendes Personal (47 Prozent), fehlende wirtschaftliche Kenntnisse (46 Prozent) sowie fehlende Marktaussichten (43 Prozent).

In den anderen Arbeitspaketen des Projekts werden Maßnahmen entwickelt, die Unternehmen dabei unterstützen, diese Hemmnisse zu überwinden. Darüber hinaus bestehende rechtliche Hemmnisse werden in Abschnitt 3.5 detaillierter dargestellt.

Neben der Förderung einer sicheren und vernetzten Infrastruktur zur gemeinsamen Datenbewirtschaftung macht die Bereitstellung von vertrauenswürdigen Cloud-Diensten für Unternehmen einen wesentlichen Anwendungsbereich von Gaia-X aus. Cloud-Dienste können beispielsweise Mail-, Office- und CRM-Software sowie virtuelle Server oder Rechenleistung auf Abruf umfassen.

Abbildung 2.4 veranschaulicht den Status quo der Cloud-Nutzung durch Unternehmen in Deutschland.

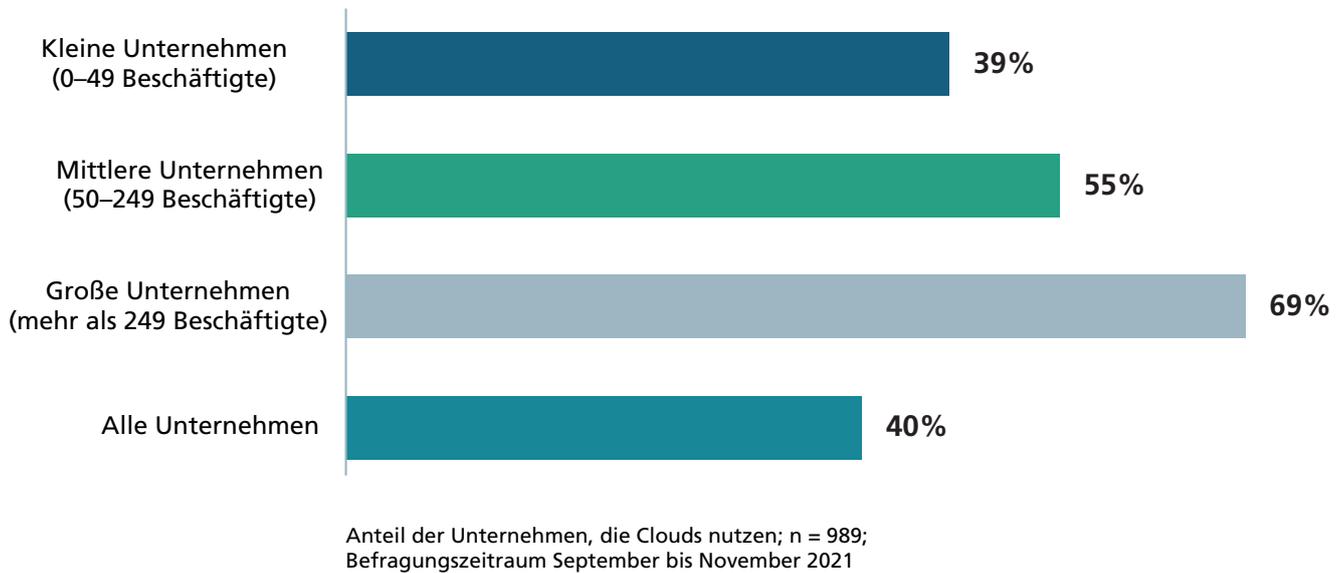


Abbildung 2.4: Cloud-Nutzung (Institut der deutschen Wirtschaft)

Auf gesamtdeutscher Ebene nutzen 40 Prozent der befragten Unternehmen Cloud-Dienste als Anwender. Damit reiht sich der Cloud-Nutzungsanteil in den Wachstumstrend ein, der in anderen Befragungen festgestellt wurde. Für 2020 ermittelte eine Umfrage von Destatis beispielsweise einen Cloud-Nutzungsanteil von 33 Prozent der Unternehmen ab 10 Beschäftigten, 2018 waren es noch 22 Prozent (Destatis 2021).

Der Anteil der Unternehmen, die Cloud-Dienste nutzen, nimmt mit der Unternehmensgröße zu. 39 Prozent der kleinen Unternehmen, 55 Prozent der mittleren und 69 Prozent der großen Unternehmen nutzen Cloud-Dienste. Bei einem Großteil der Unternehmen in Deutschland ist die Cloud-Nutzung bereits im Unternehmensalltag angekommen. Jedoch bleibt auch hier noch viel Potenzial ungenutzt, insbesondere wenn Unternehmen derzeit nur eher niederschwellige Cloud-Dienste wie beispielsweise Mail-Software verwenden und eher fortgeschrittene Cloud-Dienste wie beispielsweise Rechenleistung auf Abruf (noch) keine Rolle spielen.

Die Berührungspunkte zwischen Unternehmen und Cloud-Diensten werden im folgenden Kapitel wieder aufgegriffen und mit der Bekanntheit von Gaia-X in Beziehung gesetzt.

2.2 Monitoring Gaia-X

Cloud Computing bietet für Unternehmen zahlreiche Vorteile. Beispielsweise kann mittels Cloud-Lösungen jeder Mitarbeiter von jedem Ort auf benötigte Daten und Software zugreifen. Zusätzlich können Speicher- und Rechenkapazitäten unkompliziert zugebucht oder abgegeben werden, um kosteneffizient auf aktuelle Bedarfe zu reagieren. Entsprechend hat die Nutzung von Cloud Computing in den vergangenen Jahren stark zugenommen (vgl. Abschnitt 2.1). Besonders profitieren konnten davon US-amerikanische sowie asiatische Unternehmen, da diese beim weltweiten sowie europäischen Umsatz die größten Marktanteile auf sich vereinen (Statista, 2021; KPMG, 2021). Vor diesem Hintergrund erklärt sich auch die

Forderung von Bundeswirtschaftsminister Altmaier 2019 nach einer europäischen Cloud-Infrastruktur, um unter anderem Datensouveränität zu gewährleisten (BMW, 2019). Zu diesem Zweck wurde in der zweiten Jahreshälfte 2019 die Gaia-X-Initiative (vgl. Abschnitt 1.2) vorgestellt (BMW und BMBF 2019).

Kernergebnisse:

Noch sind die Wahrnehmung und die Kenntnis über Gaia-X bei Unternehmen gering. Anhand der Suchanfragen nach den Begriffen »Gaia-X« und »Cloud Computing« auf der Internet-Suchmaschine Google (Abbildung 2.5) wird deutlich, dass trotz größerer Schwankungen mehr oder weniger konstant nach dem Thema Cloud Computing gesucht wird. Der Zeitraum umfasst dabei vom zweiten Halbjahr 2019 bis zum aktuellen Rand. Es wird deutlich, dass es zu jedem Zeitpunkt weniger Suchanfragen nach Gaia-X gab als nach Cloud Computing selbst. Auch ist von einem niedrigen Niveau ausgehend, kein klares Wachstum des Suchinteresses nach Gaia-X festzustellen. In diesem Zusammenhang verwundern auch nicht die

Ergebnisse einer Umfrage aus September und Oktober 2020 (Röhl et al. 2021), nach der lediglich 6,5 Prozent der befragten Unternehmen aus Industrie und industrienahen Dienstleistungen und zehn Prozent der befragten als digital eingestuft Unternehmen angaben, Gaia-X zu kennen. In der Umfrage für das vorliegende Projekt (vgl. Abschnitt 2.1) gaben immerhin bereits mehr als neun Prozent aller befragten Unternehmen an, dass sie Gaia-X kennen.

Vor dem Hintergrund der wachsenden Bedeutung von Cloud-Diensten allgemein sowie der angestrebten Vorteile von Gaia-X, wie dem sicheren Teilen von Daten über verschiedene Cloud-Anbieter hinweg, ist davon auszugehen, dass die Bekanntheit von Gaia-X in naher Zukunft zunimmt. Zudem ist Gaia-X noch in der Entwicklungsphase (Gaia-X European Association for Data and Cloud AISBL 2021), nach deren Abschluss ebenfalls Fortschritte hinsichtlich Bekanntheit und Nutzung zu erwarten sind.

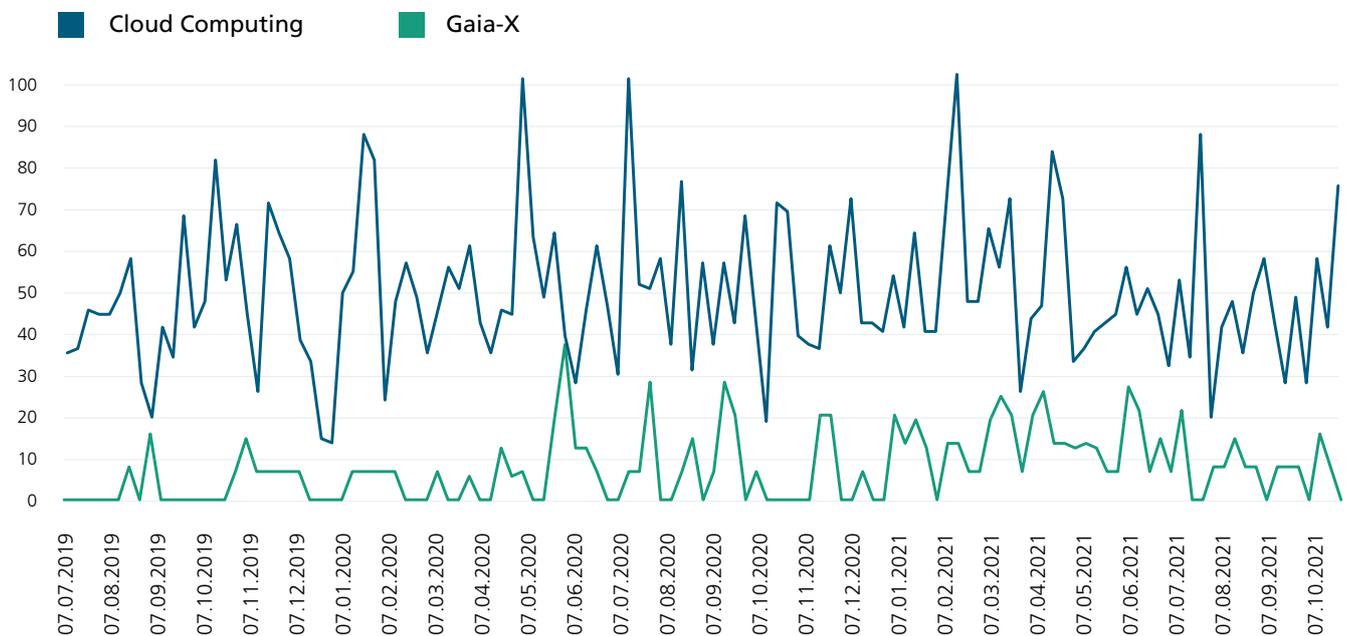


Abbildung 2.5 Indizierte wöchentliche Suchanfragen nach »Gaia-X« und »Cloud Computing« auf Google Search vom 01.07.2019 bis zum 24.10.2021. Stand: 28.10.2021; Suchanfragen aus Deutschland relativ zum Maximum an verzeichneten Suchanfragen im Zeitraum, welches den Wert 100 erhält; Datum gibt den letzten Tag der jeweiligen Woche an.

Um die zukünftige Durchdringung von Gaia-X in Wirtschaft, Öffentlichkeit und der Forschung empirisch nachzuzeichnen, wird ein Gaia-X Monitoring etabliert. Dies ermöglicht anhand eines Dashboards die niederschwellige, detailgenaue und aktuelle Verfolgbarkeit der Bekanntheit sowie der Art und des Umfangs der Diskussion zu Gaia-X. Zusätzlich können darüber Erfolge kommuniziert und politische Handlungsempfehlungen ausgesprochen werden. Um Übersichtlichkeit zu gewährleisten, wird sich das Dashboard auf circa 5 bis 10 einzelne Indikatoren beschränken, die aussagekräftige Informationen über Gaia-X mit Blick auf unterschiedliche Dimensionen beziehungsweise Bereiche enthalten. Diese stammen aus vier Kategorien, die für den Erfolg von Gaia-X entscheidend sind (vgl. Abbildung 2.6). Diese vier Kategorien sind:

Öffentlichkeit:

In der Kategorie Öffentlichkeit werden Indikatoren verwendet, die Aussagen über das Interesse und die Aufgeschlossenheit der Gesellschaft gegenüber Gaia-X ermöglichen. Nur wenn die Bevölkerung und Unternehmen Gaia-X gegenüber Interesse zeigen und es gegebenenfalls als ein Qualitätsmerkmal wahrnehmen, kann das Projekt erfolgreich sein. Mögliche Indikatoren sind die Häufigkeit von Gaia-X in Nachrichten oder in Tweets auf Twitter.

Forschung:

Die Rolle von Gaia-X in Forschungsprojekten und wissenschaftlichen Publikationen kann ebenfalls Aufschluss über die aktuelle Bedeutung von Gaia-X geben. Entsprechende wissenschaftliche Erkenntnisse stellen mögliche Mehrwerte für die Nutzung von Gaia-X dar und können so die Etablierung vorantreiben.

Wirtschaft:

Unternehmen spielen sowohl für die Nachfrage als auch für das Angebot von Daten und Anwendungen über Gaia-X eine wichtige Rolle. Damit ist die Wirtschaft ebenfalls ein zentraler Faktor für den Erfolg des Projekts. Daher werden auch Indikatoren aus diesem Bereich verwendet. Mögliche Indikatoren sind dabei die Thematisierung von Gaia-X oder generelleren Datenkompetenzen in Stellenanzeigen beziehungsweise die Verwendung entsprechender Begriffe auf Unternehmenswebseiten.

Technologie:

Die technologische Entwicklung und das entsprechende Angebot von Diensten und Software im Zusammenhang mit Gaia-X sind ebenfalls kritische Erfolgsfaktoren. Daher werden auch Aktivitäten bezüglich Gaia-X auf der Programmierer-Plattform Github in das Monitoring einbezogen.

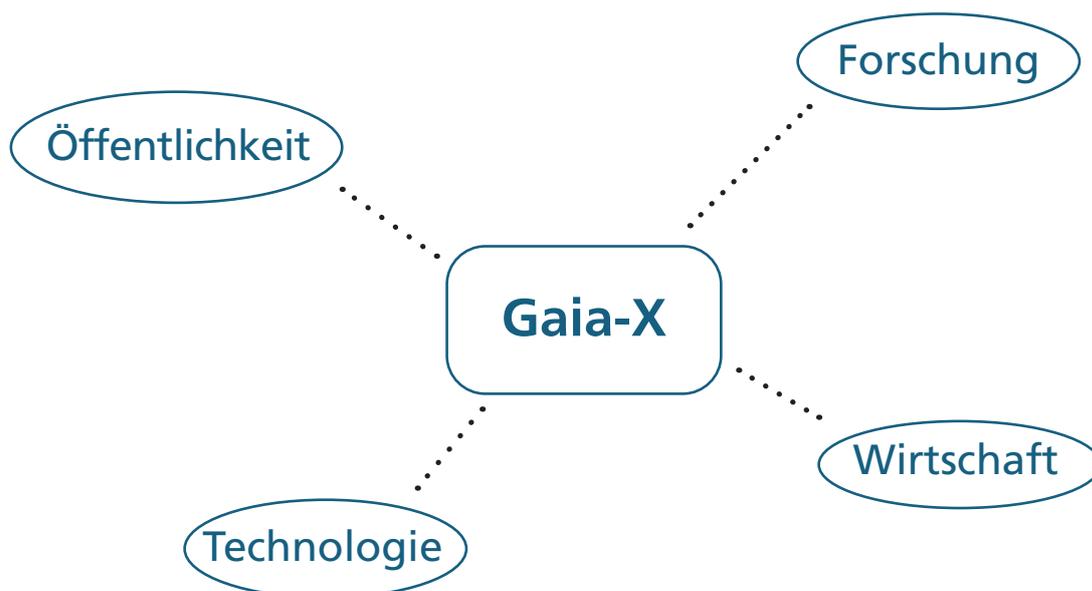


Abbildung 2.6 Dimensionen des Gaia-X Monitorings (eigene Darstellung)



2.3 Pretest Umfrageexperiment Anreizmechanismen

Im weiteren Verlauf des Projektes soll, die Resonanz deutscher Unternehmen auf verschiedene Anreizmechanismen zum Teilen von Daten untersucht werden. Für diesen Zweck sollen Unternehmensbefragungen zum Einsatz kommen. Im Detail sollen dabei Umfrageexperimente durchgeführt werden, mit denen die Reaktion auf verschiedene Anreizszenarien getestet werden kann. Im Zuge dieser Methodik werden die Unternehmen randomisiert einer von mehreren Gruppen zugewiesen, wobei jede Gruppe eine andere Version des Fragebogens erhält. Die verschiedenen Fragebogen-Versionen variieren dabei lediglich darin, dass sie unterschiedliche Anreize zum Teilen von Daten aufzeigen. Unter Anwendung statistischer Verfahren lässt sich für die in allen Versionen identischen Fragen auswerten, inwieweit Entscheidungsträger in deutschen Unternehmen auf verschiedene Anreize reagieren.

Im Zuge der quartalsweise durchgeführten ZEW Konjunkturumfrage Informationswirtschaft wurde ein Pretest implementiert, um diese Analysemethode zu erproben. Während der Feldphase (Dezember 2021 – Januar 2022) beteiligten sich an der Befragung rund 750 Unternehmen aus dem Wirtschaftszweig der Informationswirtschaft¹ und rund 450 Unternehmen aus dem verarbeitenden Gewerbe. Im Fokus des Pretests stand dabei, welche Bedeutung die Unternehmen dem Sammeln und Auswerten von Daten beimessen und welche mittelfristigen Pläne sie hinsichtlich der Datennutzung verfolgen. Im Detail sollte untersucht werden, ob die Einschätzung der Unternehmen auch davon abhängt, welche Informationen sie vor dem Ausfüllen des Fragebogens erhalten. Für diesen Zweck wurden drei verschiedene Versionen des Fragebogens erstellt, die sich lediglich im Einführungstext am Anfang des Fragebogens unterscheiden. Die Unternehmen wurden im Vorfeld zufällig der Kontrollgruppe oder einer der zwei Treatment-Gruppen zugeteilt und erhielten dementsprechend einen der drei folgenden Einführungstexte zu Beginn des Fragebogens:

Kontrollgruppe: *»Mit der zunehmenden Digitalisierung entstehen auch immer mehr Daten. Die folgenden Fragen beziehen sich daher auf die Datennutzung in Ihrem Unternehmen.«*

Treatment-Gruppe 1: *»Mit der zunehmenden Digitalisierung entstehen auch immer mehr Daten. Für Unternehmen eröffnen sich dadurch neue Möglichkeiten, Daten zu sammeln und auszuwerten. Wie wissenschaftliche Studien belegen, ist das ungenutzte Potenzial in den meisten Unternehmen allerdings groß. Die folgenden Fragen beziehen sich daher auf die Datennutzung in Ihrem Unternehmen.«*

Treatment-Gruppe 2: *»Mit der zunehmenden Digitalisierung entstehen auch immer mehr Daten. Für Unternehmen eröffnen sich dadurch neue Möglichkeiten, Daten zu sammeln und auszuwerten, um Prozesse, Produkte oder Dienste weiterzuentwickeln. Wie wissenschaftliche Studien belegen, können Unternehmen durch die Datennutzung ihre Innovationstätigkeit, Produktivität und Gewinne erhöhen. Die folgenden Fragen beziehen sich daher auf die Datennutzung in Ihrem Unternehmen.«*

Während der Einführungstext für die Kontrollgruppe nur das Thema einleitet, enthalten die Einführungstexte der beiden Treatment-Gruppen zusätzliche Informationen zum Thema Datennutzung. Treatment 1 hebt hervor, dass sich für Unternehmen nun zwar neue Möglichkeiten der Datennutzung ergeben, dass aber zeitgleich das ungenutzte Potenzial in vielen Unternehmen groß ist. Treatment 2 fokussiert hingegen auf die möglichen Einsatzzwecke und positiven Auswirkungen der Datennutzung auf den Unternehmenserfolg. Um den Effekt dieser Treatments zu messen, wurde im weiteren Verlauf des Fragebogens erfasst, in welcher Form die Unternehmen zukünftig Daten nutzen möchten und inwieweit sie den jeweiligen Einsatz als wichtig für ihren Unternehmenserfolg erachten.

Kernergebnisse:

Im Rahmen des beschriebenen Pretests konnte zunächst sichergestellt werden, dass die Randomisierung der Unternehmen auf die drei Gruppen zuverlässig funktioniert und dass die für die Zuordnung genutzte Methodik für Folgeexperimente beibehalten werden kann. Zudem ergab der Pretest, dass die Stichprobengröße von insgesamt rund 1.200 teilnehmenden Unternehmen ausgereicht hat, um in einem Experiment mit drei Gruppen statistisch signifikante Treatmenteffekte zu identifizieren.

Exemplarisch für die inhaltlichen Ergebnisse des Pretests präsentiert Abbildung 2.7 einen Frageblock des Umfrageexperiments. Die Grafik zeigt an, für welche Zwecke die Unternehmen eine Nutzung von Daten in den kommenden zwei

¹ Zum Wirtschaftszweig Informationswirtschaft zählen die Branchen IKT-Hardware, IKT-Dienstleister, Mediendienstleister sowie wissensintensive Dienstleister. Für nähere Details zur Umfrage siehe: <https://www.zew.de/WS380>.

Jahren planen. Dabei sind die jeweiligen Unternehmensanteile sowohl für die Kontrollgruppe als auch für die zwei Treatment-Gruppen dargestellt. Die Mehrheit der befragten Unternehmen in der Informationswirtschaft und im verarbeitenden Gewerbe plant den Einsatz von Daten für die im Fragebogen erfassten Zwecke. Zudem zeigt sich, dass die Zustimmungswerte in beiden Treatment-Gruppen tendenziell höher ausfallen als in der Kontrollgruppe. So planen in der Informationswirtschaft 82 Prozent der befragten Unternehmen in der Kontrollgruppe, dass sie in den kommenden zwei Jahren Daten für die Steuerung oder Verbesserung von Prozessen einsetzen wollen. In Treatment-Gruppe 1 beläuft sich der Anteil hingegen auf 89 Prozent und in Treatment-Gruppe 2 auf 86 Prozent. Die in der Abbildung mit einem „*“ gekennzeichneten Werte weichen auf einem statistisch signifikanten Niveau ($p < 0,1$) vom Wert der Kontrollgruppe ab. Alle signifikanten Differenzen zwischen den Treatment-Gruppen und der Kontrollgruppe sind positiv. Somit führen die in den Einführungstexten enthaltenen Informationen dazu, dass ein höherer Anteil an Unternehmen

angibt, zukünftig Daten für einen spezifischen Zweck nutzen zu wollen.

Zusammengefasst bietet das vorgestellte Umfrageexperiment eine Detailsicht darauf, wie sich Informationen auf geplante Entscheidungen von Unternehmerinnen und Unternehmern auswirken können. Aus solch einem fokussierten Blick auf die Effekte von Informationsanreizen lassen sich im weiteren Verlauf auch Rückschlüsse darauf ziehen, welche Auswirkungen größere Informationskampagnen oder die Dissemination der Ergebnisse des IEDS-Projekts haben könnten. Mit den ersten Erkenntnissen aus dem Pretest können darüber hinaus Umfrageexperimente entworfen werden, um verschiedene Anreize zum Teilen von Daten miteinander zu vergleichen. Das Teilen von intern gewonnenen Daten über die Unternehmensgrenzen hinaus kann mit vielen Vorbehalten einhergehen. Mit unterschiedlichen Treatments soll getestet werden, welche Mechanismen diesen Vorbehalten entgegenwirken, Hürden abbauen und damit die Bereitschaft zum Teilen von Daten erhöhen können.

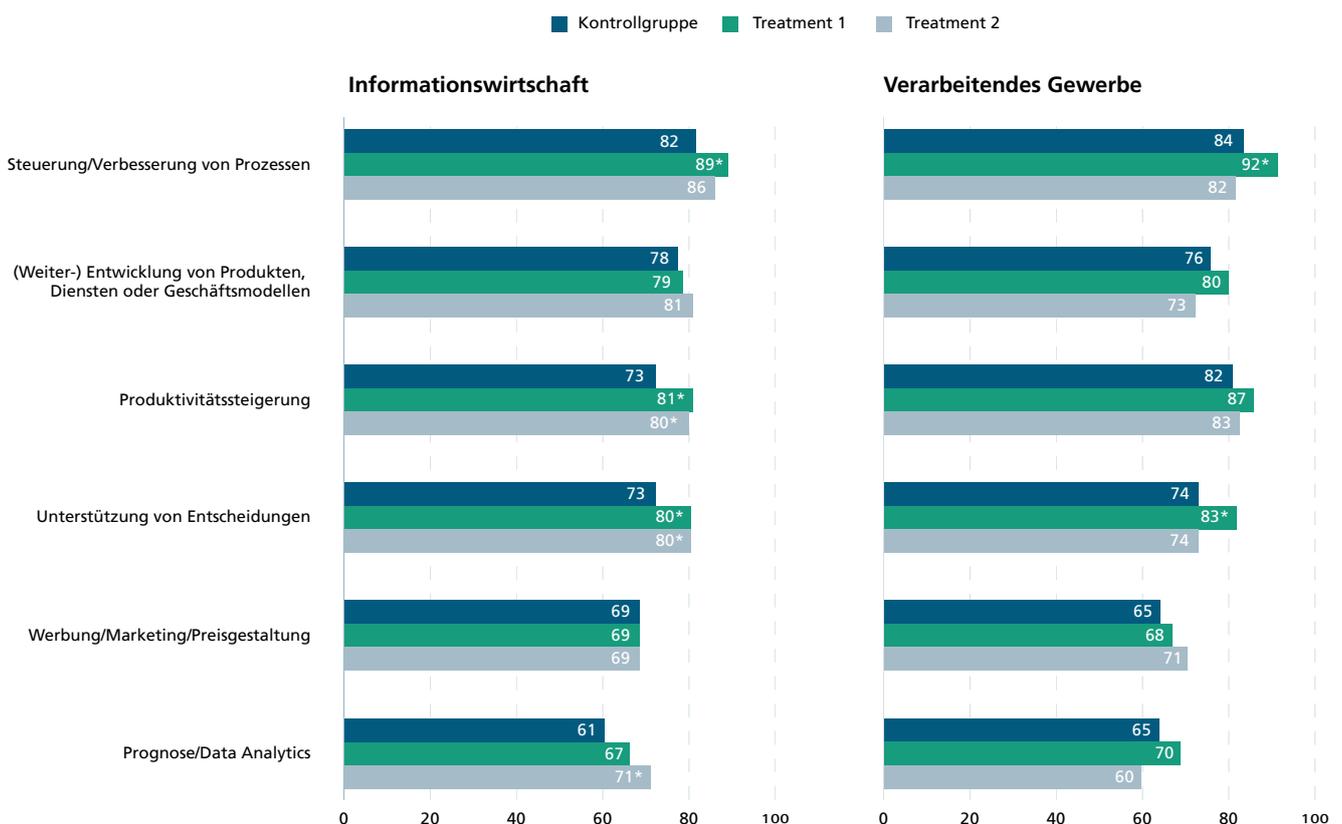


Abbildung 2.7: Einsatzzwecke für die Nutzung von Daten, nach Kontroll- und Treatment-Gruppen. Lesehilfe: Anteil der befragten Unternehmen, die auf die Frage »Planen Sie eine Nutzung der Daten für diese Zwecke in den kommenden zwei Jahren?« mit ja geantwortet haben. In der Kontrollgruppe gaben 82 Prozent der befragten Unternehmen der Informationswirtschaft an, in den kommenden zwei Jahren Daten zur Steuerung und Verbesserung von Prozessen einsetzen zu wollen. In der Gruppe, die Treatment 1 präsentiert bekam, liegt dieser Anteil bei 89 Prozent. Werte, die mit einem Stern gekennzeichnet sind, unterscheiden sich mindestens auf dem 10%-Niveau signifikant vom Wert der Kontrollgruppe.

3 Anreize und Anforderungen zur Teilnahme am Data Sharing – Forschungsüberblick

Zentraler Aspekt des IEDS-Projekts ist es, Anreize für und Anforderungen an Organisationen zur Teilnahme an Daten-ökosystemen und an Data Sharing zu ermitteln. Die Analyse dieser Forschungsaspekte findet dabei in Fokusthemen statt, die einen holistischen Blick auf das Data Sharing werfen und mögliche Potenziale, Herausforderungen und Anreize aufzeigen. Die Ausarbeitung der Ergebnisse im IEDS-Projekt wird in Form von Verbundforschung durchgeführt, indem die Anreize und Anforderungen für das Data Sharing im unternehmerischen Kontext aus sowohl technischer als auch ökonomischer Perspektive analysiert werden. Die Analyse findet dabei in den Fokusthemen Datenstrategie, Datenmanagement, datengetriebene Geschäftsmodelle, Datenbewertung und Datenrecht statt (vgl. Abbildung 1.3). Um den ganzheitlichen Blick auf das Data Sharing und dessen Anreize und Anforderungen zu gewährleisten, wurde darüber hinaus ein Forschungsüberblick zum Data Sharing erarbeitet (vgl. Abschnitt 3.1), der einen Anforderungskatalog und eine Forschungslandkarte bietet. In diesem Kapitel werden die ersten Ergebnisse der IEDS-Forschung präsentiert.

3.1 Forschungsüberblick »Data Sharing«

Mit dem unternehmensübergreifenden Datenaustausch ergeben sich für Unternehmen neue strategische Möglichkeiten, die Ressource Daten zur Weiterentwicklung der eigenen Prozesse und Produkte zu nutzen (Richter und Slowinski 2019). Eine einheitliche und differenzierte Definition des Begriffes Datenaustausch gibt es nach aktuellem Stand in der Literatur noch nicht. Allerdings beschreibt die folgende Definition im Rahmen der Datenstrategie der Bundesregierung die zentralen Aspekte:

Beim Data Sharing geben »[...] verschiedene Akteurinnen und Akteure [...] Daten weiter an Dritte oder nutzen diese gemeinsam auf der Basis von kommerziellen oder nichtkommerziellen Vereinbarungen, oder auf Basis von zwingenden gesetzlichen Vorschriften« (Bundeskanzleramt 2021, S. 110).

Warum der Austausch von Daten mit so großen Potenzialen verbunden ist und für Unternehmen vor allem auch ökonomisch interessant ist, zeigt der von der Europäischen Kommission auf circa 324,86 Milliarden Euro geschätzte Wert der Datenwirtschaft in Europa am Ende des Jahres 2019. In den nächsten Jahren wird bis 2025 ein Wachstum auf einen Wert von schätzungsweise 829 Milliarden Euro innerhalb der EU-27 Staaten prognostiziert (Mildebrath 2021). Nichtsdestotrotz sind sich Unternehmen häufig nicht im Klaren über den eigentlichen Wert ihrer eigenen Datenressourcen sowie über die Vorteile der Partizipation im unternehmensübergreifenden Austausch (Parvinen et al. 2020; Azkan et al. 2020c).

Rechtliche Standards wie die Datenschutz-Grundverordnung oder auch der geplante Data Governance Act definieren den Rahmen, um den Austausch und Schutz von Daten konform den europäischen Standards zu gewährleisten (Europäische Union 2016; Europäische Kommission 2020c). Somit bildet die Existenz eines angemessenen rechtlichen Rahmens eine von zahlreichen Anforderungen für den unternehmensübergreifenden Datenaustausch. Basierend auf dieser Anforderung beschäftigt sich die 2019 ins Leben gerufene europäische Initiative Gaia-X mit Zielen wie der Schaffung einer sicheren Dateninfrastruktur (vgl. Abschnitt 1.2).

Anforderungskatalog an unternehmensübergreifenden Datenaustausch

Ein Anforderungskatalog an unternehmensübergreifenden Datenaustausch dient der Auflistung der notwendigen Bedingungen, die erfüllt sein sollten, um die verschiedenen Akteure zum Datenaustausch zu motivieren und sie auch während des Prozesses zu unterstützen. Aus der Literatur wurden erste Anforderungen abgeleitet, die in einem iterativen Verfahren durch Workshops und Gaia-X Use Cases angepasst und ergänzt wurden.

Beispiele für generelle Anforderungen an unternehmensübergreifenden Datenaustausch sind Vertrauen und Transparenz, die in der Literatur besonders prominent diskutiert wurden (Dahlberg und Nokkala 2019). Immer noch ist fehlendes Vertrauen zwischen Organisationen ein großes Hindernis für den Austausch von Daten, dem man mit vertrauensvollen Strukturen sowie Identifizierungsprozessen und der Verwendung von Verschlüsselungstechnologien entgegenzuwirken versucht (Gelhaar und Otto 2020; Dahlberg und Nokkala 2019). Ebenso bedeutend, aber zugleich auch schwierig zu realisieren, ist die

Anforderung der Transparenz. Diese stellt den Datenaustausch vor große Herausforderungen, da Transparenz von den einzelnen Akteuren durch Einblicke in ihre Daten selbst ermöglicht werden muss. Die Daten müssen andererseits trotzdem stets geschützt bleiben.

Anschließend wurde das literaturbasierte Ergebnis in mehreren Iterationen weiter differenziert und somit schrittweise weiter vervollständigt. Dazu zählte die Durchführung von zwei Workshops sowie der Abgleich der Anforderungen mit den konzeptionellen Use Cases des Gaia-X-Projekts. Die beiden Workshops wurden mit unterschiedlich zusammengesetzten Expertengruppen durchgeführt, die alle in verschiedenen Arbeitspaketen des IEDS-Projekts tätig sind. Durch die Workshops wurden die Anforderungen der Literatur komplementiert, mit weiteren relevanten Teilaspekten weiter spezifiziert sowie übergeordneten Kategorien zugeordnet. Ausgewählte Anforderungen an den unternehmensübergreifenden Datenaustausch werden in Abbildung 3.1 dargestellt. Dabei ist zu erkennen, dass sich die Anforderungen entsprechend ihrem thematischen Schwerpunkt kategorisieren lassen. Im Laufe der einzelnen Iterationen wurde dabei deutlich, dass zwischen



Abbildung 3.1 Exemplarische Anforderungen für den unternehmensübergreifenden Datenaustausch (eigene Darstellung basierend auf den Ergebnissen der durchgeführten Auswertung)

generellen Anforderungen (1) sowie Anforderungen zum rechtlichen Rahmen (2) und der technischen Umsetzung (3) differenziert werden muss. Neben den durchgeführten Workshops wurde durch den Abgleich der literaturbasierten Anforderungen mit einer Vielzahl an Gaia-X Use Cases eine gezielte Verknüpfung geschaffen. Hierbei stellten sich weitere Anforderungen als bedeutsam für den Datenaustausch heraus, wie die Skalierbarkeit, die Interoperabilität oder auch die Konformität zu europäisch geltenden Gesetzgebungen wie der Datenschutz-Grundverordnung (DSGVO). Ferner ist die Interoperabilität von Daten und Diensten von großer Bedeutung, da diese den Datenaustausch sowie die Nutzbarkeit der Daten enorm beeinflusst. Im Allgemeinen wird deutlich, dass der Anforderungskatalog einige Anforderungen unabhängig vom Anwendungskontext beinhalten muss, während vereinzelte Anforderungen in Abhängigkeit von den spezifischen Rahmenbedingungen des Anwendungsfalls definiert werden müssen.

Forschungslandkarte zum unternehmensübergreifenden Datenaustausch

Zur Verdeutlichung der relevanten Themen im Bereich der Datenwirtschaft sowie der Fokusthemen des IEDS-Projekts wurde eine Forschungslandkarte konzipiert, die Ansätze aus der Literatur mit den Arbeitspaketen des Projekts zusammenbringt und mögliche Themen für Modul B aufzeigt (vgl. Abbildung 3.2). Diese konzeptualisiert die 16 Innovationstreiber und den zukünftig relevanten Forschungsbedarf innerhalb der vier Kerndimensionen des unternehmensübergreifenden Datenaustauschs. Die Forschungslandkarte gibt einen strukturierten Einblick in die künftig ausschlaggebenden Themen und Anreize der Datenwirtschaft.

Die **Datenstrategie** und das **Datenmanagement** befähigen Unternehmen, ihre Daten sicher und effizient zu verwalten. Ein zentraler Aspekt im Rahmen dieser Zielsetzung sind Data-Governance-Mechanismen (vgl. Abschnitt 1.4). Der Fokus von Data Governance liegt dabei auf der Qualität und Sicherheit

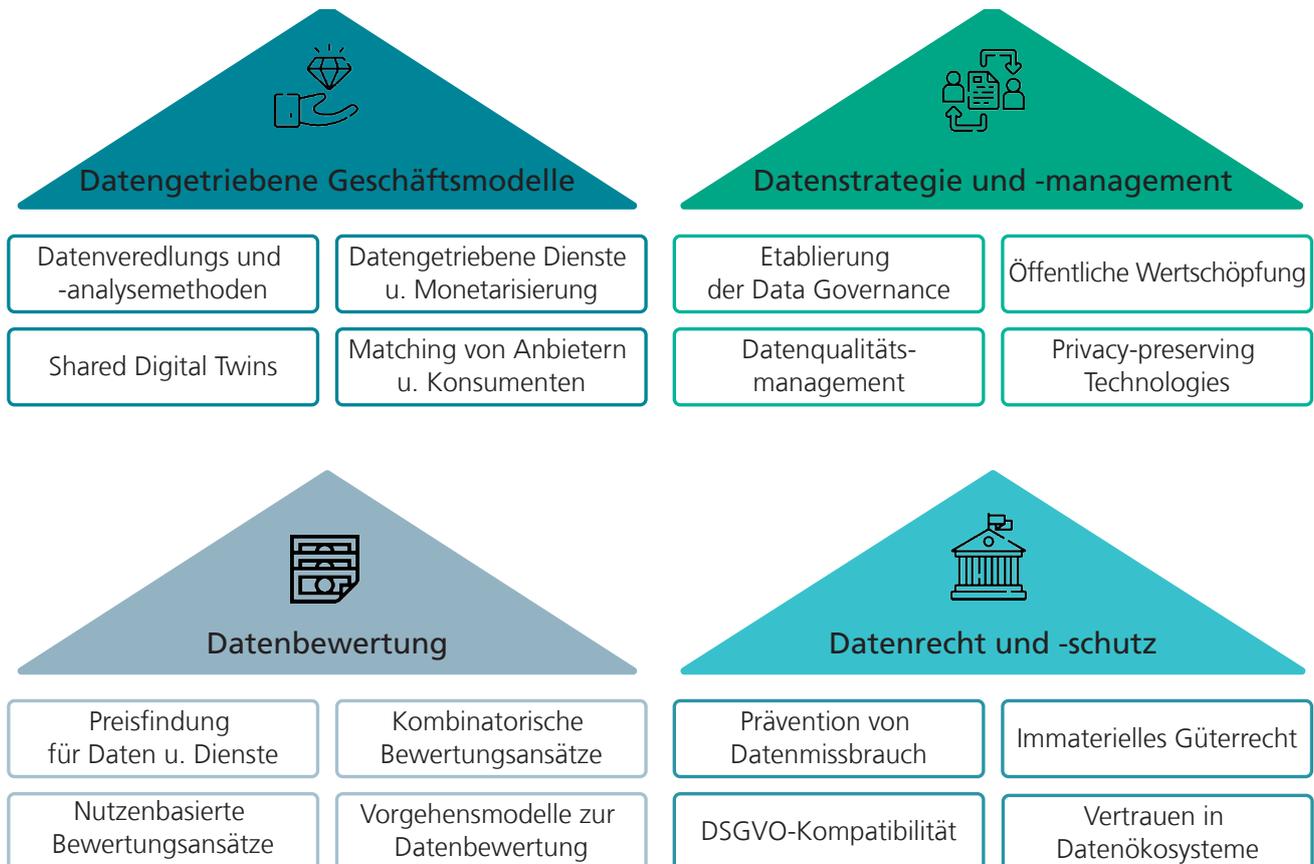


Abbildung 3.2 Die vier Kerndimensionen der Forschungslandkarte (eigene Darstellung)

der Datenressourcen. Sowohl unternehmensintern als auch unternehmensübergreifend müssen strategische Frameworks und Strukturen konzipiert werden, die dazu beitragen, den Datenaustausch und das Datenmanagement in verantwortlicher Weise zu gestalten und Kompetenzen im Umgang mit Daten aufzubauen (van den Broek und van Veenstra 2015; Lis und Otto 2020). Aus strategischer Perspektive müssen Unternehmen Instrumente entwickeln, mit denen die Verarbeitung von Daten gelingt. Eine nachhaltige Datenstrategie sorgt langfristig für den Aufbau notwendiger Kompetenzen, wie z. B. der Konzeption von digitalen Zwillingen oder angepassten Werkzeugen zur Datenanalyse (Cirullies und Schwede 2021). Zunehmend treten auch die Privatsphäre und die Sicherheit behütende Technologien in den Fokus des unternehmensübergreifenden Datenaustauschs. Insbesondere kryptografische Methoden bieten ein hohes Maß an Sicherheit und lassen intermediäre Datenvermittler obsolet werden (Agahari et al. 2021; Dahlberg und Nokkala 2019). Die Covid-19-Krise hat durch die Notwendigkeit, Gesundheitsdaten zu aggregieren, die Relevanz des unternehmensübergreifenden Datenaustauschs manifestiert. Insbesondere in der öffentlichen Verwaltung kann der Datenaustausch zu einer gemeinschaftlichen Wertschöpfung beitragen (Susha et al. 2019).

Im Themenbereich **datengetriebene Geschäftsmodelle** liegt der Fokus auf datenbasierten Diensten und ihrer ökonomischen Bedeutung (vgl. Abschnitt 1.4). Steigende Rechen- und Speicherkapazitäten unterstützen die Entwicklung datengetriebener Geschäftsmodelle (Parvinen et al. 2020). In Zukunft gilt es, Mechanismen und Datenveredelungstechniken, wie Analyse- und Informationsdienste, zu entwickeln, die den Nutzen von Rohdaten steigern (Fruhirth et al. 2020). Die ökonomischen Anreize für den Datenaustausch und das Bereitstellen der Dienste im Rahmen von Geschäftsmodellen stellen ein wichtiges Element des unternehmensübergreifenden Datenaustauschs dar. Datengetriebene Geschäftsmodelle

können aus unterschiedlichen Perspektiven betrachtet werden und bieten demnach unterschiedliche Implikationen für verschiedene Akteure in Datenökosystemen. Darauf basierend können archetypische Muster für Datenmarktplätze und deren Teilnehmer entwickelt werden (Gelhaar et al. 2021b). Insbesondere bedarf es der Erforschung von Instrumenten zur adäquaten Zusammenführung von Datennachfrage und -angebot durch Metadaten und Matching-Algorithmen (Susha et al. 2017). Im Zuge der aufstrebenden Initiativen im Bereich des Datenaustauschs entstehen vielschichtige Referenzmodelle und -architekturen.

Bei der **Datenbewertung** stehen die Wertfeststellung sowie die ökonomischen Auswirkungen und die ökonomische Bedeutung des Datenaustauschs im Fokus. Dazu zählen beispielsweise die Bestimmung des kombinatorischen Werts von Daten und der Tausch von Daten zum gegenseitigen Nutzen. Komende Forschungsarbeiten können sich auf die Preisgestaltung von Datensätzen fokussieren, bspw. unter Berücksichtigung von nutzenbasierten oder kombinatorischen Bewertungsansätzen (Badewitz et al. 2020). Zudem können Vorgehensmodelle entwickelt werden, die den Prozess der Datenbewertung vereinfachen.

Im Bereich des **Datenrechts** liegt der Fokus auf Compliance-Regeln, vertrags- und haftungsrechtlichen Konzepten der Datenbewirtschaftung, immateriell-güterrechtlichen Schutzrechten sowie der Datensicherheit, jeweils mit einer rechtsökonomischen Folgebewertung.

Die genannten und erläuterten Kerndimensionen der Forschungslandkarte stellen ebenfalls Fokusthemen des IEDS-Projekts dar (vgl. erneut Abbildung 1.3). Nachfolgend werden deren erste Ergebnisse, beginnend mit dem Themenbereich der Datenstrategie und dem effizienten Datenmanagement, präsentiert.

3.2 Datenstrategien und effizientes Datenmanagement

Die Betrachtung von Daten als strategische Ressource ermöglicht dabei völlig neue Formen der Wertschöpfung und Optimierungspotenziale, sodass Unternehmen oftmals ihre betrachtete Datenmenge nicht nach der Strategie, sondern die Strategie nach den potenziell nutzbaren Daten ausrichten. Eine Datenstrategie gibt dabei eine Referenz über Methoden, Tools, Dienste, Architekturen und Nutzungsmuster für die Verwaltung und Nutzung von Daten (Gurevich und Dey 2018). Eine Datenstrategie kann als Plan definiert werden, der die Festlegung von Zielen, die Identifizierung von Datenquellen und die Nutzung von Analysen erfordert, um durch strategisches Denken in Zusammenarbeit mit technologischem Know-how die richtigen Fragen zu stellen und so einen Mehrwert für interne und externe Interessengruppen zu schaffen (Gür et al. 2021). Das Datenmanagement hat dabei die Unternehmensfunktion zur Planung, Steuerung und Bereitstellung von Daten (Mosley et al. 2010). Es zielt auf die effiziente Nutzung von Daten ab, da es mehrere Funktionen für die Formulierung einer Datenstrategie, die Definition von Managementprozessen, Maßnahmen und Standards, die Zuweisung von Rollen und Verantwortlichkeiten (Otto 2011) sowie das Management von Anwendungen und Systemen umfasst (Pentek et al. 2017). Im Folgenden werden Möglichkeiten aufgezeigt, um das Datenmanagement für Data Sharing effizient durchzuführen und die strategische und operative Ausrichtung eines Unternehmens danach zu richten.

Ein weiterer Teilaspekt des Datenmanagements, der insbesondere für die Wiederverwendung von Daten wichtig ist, stellt das Auffinden von benötigten Daten in internen und externen Quellen dar. Daten werden typischerweise in Verzeichnissen verwaltet oder über Datenmarktplätze angeboten und über eine Suchfunktion zur Verfügung gestellt (Spiekermann 2019). Datengüter stellen aufgrund ihrer Eigenschaften besondere Anforderungen an die Datensuche. Im Folgenden wird der im Rahmen des IEDS-Projekts verfolgte Ansatz, um die Suche nach Daten unter Verwendung aktueller Technologien zu verbessern und so Datenangebot und -nachfrage besser zusammenzubringen, dargestellt.

Agiles Datenmanagement für Data Sharing: DataOps

Um einen langfristigen, nachhaltigen Erfolg und Wettbewerbsvorteile zu erzielen, müssen Unternehmen bei der Verwaltung und Nutzung ihrer Daten einen höheren Reifegrad erreichen

(Altamony et al. 2012), damit sie an Datenökosystemen und dem Datenaustausch teilnehmen können. Die Unternehmen sehen sich jedoch mit einer Vielzahl an Schwierigkeiten konfrontiert. Diese Herausforderungen treten nicht nur auf technologischer Ebene auf, wenn es um veraltete Technologien und eine umfangreiche Softwarelandschaft geht (Abbildung 3.3), sondern auch auf organisatorischer Ebene. Oft stecken die Daten in Datensilos innerhalb der Organisation, oder das Team aus Data Scientists und Data Engineers ist nicht in der Lage, neue Datenquellen schnell zu nutzen (Hurley 2018). Unternehmen benötigen heute Datenteams, die agil sind, um so schnell wie möglich auf die Datenbedürfnisse der Stakeholder reagieren zu können (Sparapani 2019). Gleichzeitig müssen die Daten vertrauenswürdig sein, damit die Entscheidungsträger sie sorgenfrei nutzen können. Studien zeigen, dass Unternehmen eine Reihe von Hindernissen überwinden müssen, um ihren strategischen Nutzen aus Daten zu maximieren (Hurley 2018; Nexla Inc. 2018).

Laut einer von Experian Ltd. durchgeführten Studie stehen 89 % der Unternehmen vor Herausforderungen im Umgang mit Daten, die auf lange Verzögerungen bei der Gewinnung von Erkenntnissen, mangelndes Vertrauen in die Daten oder mangelnde Fähigkeit zur Nutzung der Daten zurückzuführen sind (Experian Ltd. 2019).

DataOps, Kurzform für Data Operations, ist eine unternehmensweite Datenmanagementpraxis, die den Datenfluss von der Quelle bis zur Wertschöpfung steuert mit dem Ziel, den Prozess der Wertschöpfung aus Daten zu beschleunigen (Nexla 2018). DataOps verbindet Datenersteller mit Datenkonsumenten – sowohl Menschen als auch Maschinen –, um die Zusammenarbeit und digitale Innovation zu beschleunigen, was es besonders effektiv für die enormen Mengen an hochwertigen Daten macht, die für die KI-Verarbeitung erforderlich sind (Sparapani 2019). Wie Analysen zeigen (Gür 2021), ist das zugrunde liegende Konzept und die Begrifflichkeit DataOps sehr neu. Bislang gibt es keine allgemein anerkannte Definition von DataOps. (Mainali et al. 2021) zufolge wurde der Begriff DataOps erstmalig in (Lenny 2014) verwendet, wo die Bedeutung der schnellen Ausführung von Datenanalyseaufgaben mit einfacher Zusammenarbeit und gesicherten Qualitätsergebnissen in verschiedenen Big-Data- und Cloud-Computing-Umgebungen diskutiert wird (Mainali et al. 2021).

Eine weit verbreitete Definition von DataOps bietet Ereth (2018), der DataOps als »Reihe von Praktiken, Prozessen und Technologien, die eine integrierte und prozessorientierte Sichtweise auf Daten mit Automatisierung und Methoden aus dem agilen Software-Engineering kombinieren, um Qualität, Geschwindigkeit und Zusammenarbeit zu verbessern und eine Kultur der kontinuierlichen Verbesserung zu fördern« (Ereth 2018, S. 5) definiert. Im Rahmen des IEDS-Forschungsprojekts findet eine ausgiebige Forschung von Datenmanagementpraktiken mit Hilfe von DataOps statt, um herauszufinden, wie Organisationen sich diese Techniken zu eigen machen können, damit sie erfolgreich in Datenökosystemen und am Data Sharing partizipieren können. Inspirationen und angelehnte Prinzipien für die Datenmanagementpraxis DataOps stammen aus dem Lean Management, von DevOps, Kurzform für Development Operations, agilen Methoden und dem Total Quality Management (TQM). Eine ausgiebige und tiefgründige Analyse von DataOps und dessen Kernbausteine präsentiert das IEDS-Projekt in unserer Veröffentlichung »DataOps for Data Sharing« (Gür 2021).

Während DataOps eng mit betrieblicher Effizienz, Qualität und Agilität verbunden sind, zeigen Studien, wie ein ausgereifter DataOps-Ansatz in der Unternehmenskultur entscheidende Geschäftsvorteile für langfristige und nachhaltige Wettbewerbsvorteile schaffen kann. Die DataOps-Praxis nutzt die Automatisierung und Standardisierung, um erhebliche Auswirkungen auf Datenkuratierungsdienste, Metadatenmanagement, Data Governance (Madera und Aguilera 2020) sowie andere Geschäftsfunktionen zu erzielen. Unternehmen nutzen ihre Daten, um die Effizienz zu steigern und fortschrittliche Funktionen wie KI-gesteuerte und datenintensive Anwendungen wie IoT, fortschrittliche F&E-Bemühungen und komplexe Finanzanalysen voranzutreiben (Sparapani 2019). Studien zeigen vielfältige Vorteile, die sich durch erfolgreiche

Implementierung von DataOps-Praktiken in Organisationen beobachten lassen. Einige Beispiele für erhebliche DataOps-Vorteile werden in der Studie von 451 Research (Aslett 2019) aufgezeigt. In dieser Studie führen die Autoren eine Umfrage mit 150 Vertretern von Organisationen mit mehr als 1000 Mitarbeitern durch. Der am häufigsten genannte Nutzen, der sich aus der Implementierung von DataOps-Praktiken ergibt, ist die Erleichterung von Sicherheit und Compliance als funktionsübergreifende Anliegen im Zusammenhang mit dem Datenmanagement. In Anbetracht der Kerngedanken von DataOps war ein offensichtlicher Vorteil die erhöhte geschäftliche Agilität und die schnellere Markteinführung.

Damit ein Unternehmen mit DataOps erfolgreich sein kann, müssen aber auch mögliche Probleme und Herausforderungen berücksichtigt werden, speziell wenn DataOps-Praktiken veraltete Methoden ersetzen sollen. (Mainali et al. 2021) zufolge zählen dazu die Veränderung der Unternehmenskultur, Innovation mit geringem Risiko, die Kosten für DataOps, der Übergang von Expertenteams zu funktionsübergreifenden Teams, die Verwaltung mehrerer Umgebungen, der Wissensaustausch, Tools und Technologievielfalt sowie Sicherheit und Qualität (Mainali et al. 2021).

DataOps unterstützt hochproduktive Teams mit Automatisierungstechnologien, um Effizienzgewinne sowohl bei den Projektergebnissen als auch bei den Lieferzeiten zu erzielen. Um die Vorteile nutzen zu können, ist eine stetige Anpassung und Weiterentwicklung der internen Unternehmenskultur notwendig. Da immer mehr Geschäftsbereiche Daten benötigen, um kontextbezogene Erkenntnisse zu gewinnen (Madera und Aguilera 2020), und die Teilnahme an Datenökosystemen in der heutigen Wirtschaft nahezu unabdingbar ist, ist die Implementierung von DataOps-Praktiken in Unternehmen ratsam.

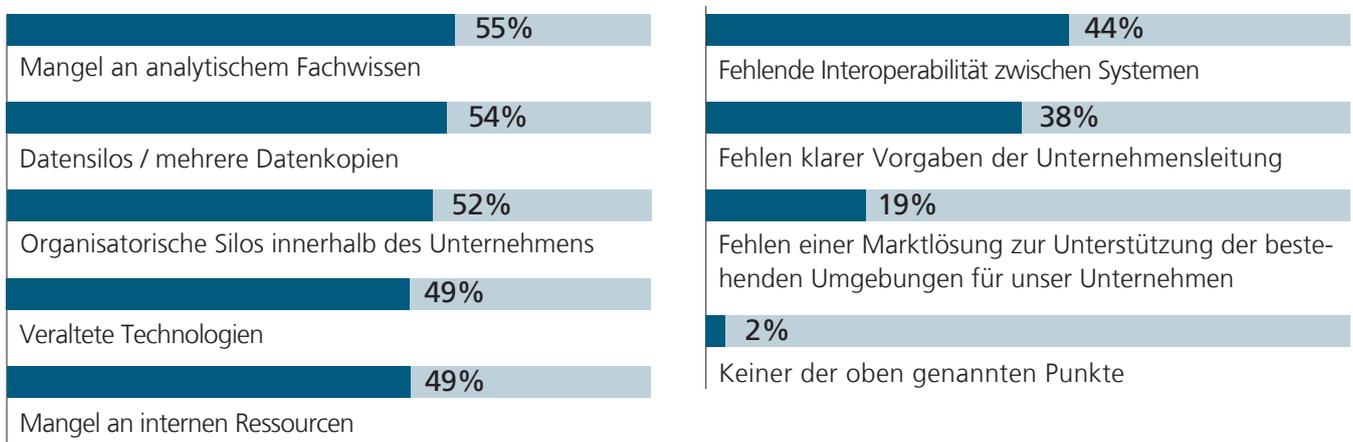


Abbildung 3.3 Hindernisse bei der Maximierung des strategischen Nutzens von Daten

Quelle: (Harvard Business Review Analytic Services 2019)

Agentenbasierte und KI-gestützte Matching-Verfahren zur Verbesserung der Datensuche

Das Ziel von Datenmanagement im Allgemeinen und von DataOps (vgl. Abschnitt 3.2) im Besonderen ist es, Daten innerhalb eines Unternehmens nutzbar zu machen. Ist der Wert von Daten (vgl. Abschnitt 3.4) erst einmal erkannt und werden sie systematisch erhoben und verwaltet, ist der nächste Schritt die Verwertung der Daten und ihre Nutzbarmachung im Rahmen eines unternehmensübergreifenden Datenaustauschs und -handels. Die Voraussetzung für einen erfolgreichen Austausch von Daten zwischen verschiedenen Parteien ist dabei das Zusammenbringen von Datenangeboten und Datennachfrage. Diese zentrale Vermittlungsaufgabe wird in der Regel von Datenmarktplätzen wahrgenommen, die über einen Katalog der verfügbaren Datengüter verfügen und die Informationen über das bestehende Datenangebot über eine Suchfunktion für potenzielle Datennutzer bereitstellen.

Für physische Produkte existieren bereits seit vielen Jahren erfolgreiche Suchverfahren, die auf die besonderen Eigenschaften des Suchgegenstands angepasst sind. Auf den großen Online-Marktplätzen, wie z. B. Amazon, werden Produkte gehandelt, die über Metadaten-Beschreibungen mit festen, in der Regel vom Produkttyp abhängigen Attributen verfügen. Neben der Suche nach Stichworten bieten diese Marktplätze die Möglichkeit, die Suchergebnisse über Filter weiter einzuschränken, indem die Nutzer für die einzelnen Produktattribute erlaubte Werte oder Wertebereiche festlegen können (Wei et al. 2013). Ergänzend zu den beschriebenen Verfahren wird zunehmend auch das Verhalten der Benutzer aufgezeichnet und mit KI-Methoden ausgewertet, um Nutzerprofile anzulegen und die Präferenzen der Nutzer in den Suchergebnissen und in Vorschlagssystemen zu berücksichtigen (Ai et al. 2017).

Die auf Datenmarktplätzen angebotenen Datengüter weisen gegenüber physischen Produkten besondere Eigenschaften auf, die sich auch auf die Suche auswirken. In Mediendaten können beispielsweise mittels moderner KI-Verfahren Bildinhalte klassifiziert und gesprochene Texte verstanden und extrahiert werden. Mit diesen Informationen können die Mediendaten über ihren Inhalt gefunden werden. Zeitliche Angaben, wie beispielsweise das Datum der Erstellung eines Datenguts oder der Zeitbereich einer Sensormessung, spielen bei der

Suche nach vielen Datengütern wie Finanz- und Unternehmensdaten, Adressdaten, Internet-of-Things- und Sensordaten oder Forschungsdaten eine große Rolle. Viele Datengüter wie Karten- und Geodaten, Sensordaten, aber auch Umfragedaten haben zudem einen starken Ortsbezug. Hinzu kommt, dass für die Interpretation von Datengütern wie Sensordaten, medizinische Daten oder Forschungsdaten in der Regel Informationen über die Art der Entstehung, die verwendeten (Mess-)Methoden und die bereits erfolgten Verarbeitungsschritte erforderlich sind (Koutroumpis et al. 2017).

Diese Besonderheiten von Daten als immaterielles handelbares Gut stellen Marktplätze und insbesondere die Datensuche daher vor besondere Herausforderungen. Hierzu zählen die Ermöglichung einer detaillierten zeitlichen und örtlichen Eingrenzung der Suchergebnisse (Kacprzak et al. 2018), die Bewertung der Wiederverwendbarkeit von Datengütern und das im Voraus durchzuführende Abschätzen ihrer Eignung für den jeweiligen Verwendungszweck (Kacprzak et al. 2018), die komplexe Analyse und Verknüpfung von Informationen aus mehreren Datensätzen (Koesten et al. 2017) sowie die tiefgreifende Extraktion von Metadaten und Analyse von Datensätzen zur Lieferung besonders präziser Suchergebnisse (Chapman et al. 2020).

Die letzten Jahre haben gezeigt, dass sich zahlreiche Datenmarktplätze, wie etwa der Azure Data Marketplace, nicht etablieren konnten und den Betrieb einstellen mussten (Spiekermann 2019). Gründe liegen unter anderem in Bedenken der Datenanbieter hinsichtlich der Datensicherheit, des Schutzes des intellektuellen Eigentums, des unklaren Wertes von Datengütern, aber auch darin, dass keine passenden Datensätze gefunden werden konnten (Röhl et al. 2021).

Eines der Ziele innerhalb des IEDS-Projekts ist es, einige der genannten Herausforderungen durch den Einsatz innovativer Verfahren aus den Bereichen der Künstlichen Intelligenz und der agentenbasierten Simulation zu adressieren und über die Verbesserung der Datensuche auf Datenmarktplätzen deren Akzeptanz zu erhöhen, um daraus letztlich Anreize für den unternehmensübergreifenden Datenaustausch zu schaffen.

Agentenbasierte Simulations- und Testumgebung: Das Konzept

Der im IEDS-Projekt verfolgte Ansatz zur Verbesserung der Zusammenführung von Datenangebot und -nachfrage setzt sich zum einen aus den verbesserten Suchverfahren und zum anderen aus einer Simulations- und Testumgebung zusammen, die es ermöglicht, die Leistungsfähigkeit des Suchverfahrens zu messen und verschiedene Ansätze systematisch zu vergleichen.

Um unterschiedliche Aspekte des Angebots- und Nachfrage-Matchings aus Sicht der Datenanbieter und der Datennutzer abbilden zu können, soll die geplante Simulationsumgebung folgende Anforderungen erfüllen:

- Als Vergleichsreferenz für alle Experimente soll die typische Suchfunktionalität eines Marktplatzes mit Stichwort- und facetierter Suche dienen. Diese Suchfunktionalität

muss bezüglich der Verarbeitung und Indizierung neuer Daten und der technischen Behandlung von Suchanfragen erweiterbar sein, um die bestehende Suche gezielt (durch KI-basierte Verfahren) erweitern und auf Datengüter spezialisieren zu können.

- Die besonderen Eigenschaften von Datengütern werden in den untersuchten Szenarien berücksichtigt. Hierzu kann es notwendig sein, für Datenanbieter und Datennutzer bestimmte Verhaltensmuster zu hinterlegen und die Interaktion mehrerer Akteure zu ermöglichen.
- Für die Auswertung der Experimente wird ein Rahmenwerk erstellt, das alle relevanten Daten einer Simulation protokolliert und Werkzeuge zur Analyse der Ergebnisse bereitstellt.

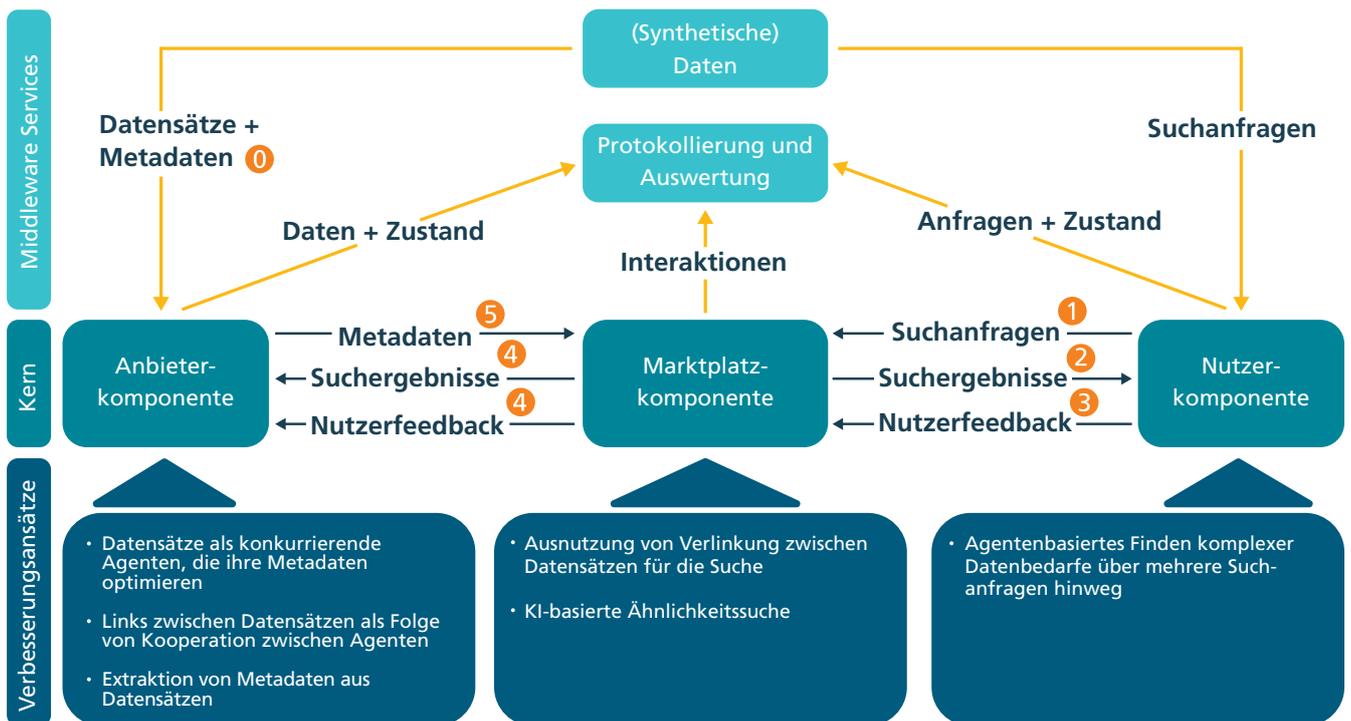


Abbildung 3.4: Simulationsumgebung und mögliche Ansätze zur Verbesserung der Datensuche (eigene Darstellung)



Diese Anforderungen wurden in das in Abbildung 3.4 dargestellte Konzept der Simulations- und Testumgebung überführt. Der zentrale Simulationskern wird dabei von der Marktplatzkomponente, die die Suchfunktionalität beinhaltet, und den Datenanbieter- und Datennutzerkomponenten gebildet. Wenn der zu testende Ansatz ein komplexes Verhalten von Datenanbieter und Datennutzer und Interaktionen zwischen ihnen erfordert, werden die Anbieter- und Nutzerkomponenten auf Basis einer agentenbasierten Simulationsumgebung realisiert. Unter einem Agenten wird hierbei eine autonome Einheit verstanden, die über einen eigenen Zustand (z. B. Datengut) verfügt, mit anderen Agenten (z. B. Datenanbietern oder Datennutzern) und seiner Umwelt (z. B. dem Marktplatz) interagiert und autonome Entscheidungen trifft (Jackson et al. 2017). Die Marktplatzkomponente verfügt über ein Interaktionsmodell, mit dessen Hilfe Datenanbieter und Datennutzer mit dem Marktplatz kommunizieren können. Die technische Basis der Marktplatzkomponente wird von einem bestehenden und erweiterbaren Suchsystem wie z. B. Apache SOLR¹ gebildet. Ergänzt wird dieser Simulationskern um unterstützende Services, die beispielsweise die Erzeugung von synthetischen Daten und Suchanfragen sowie die Protokollierung und Auswertung der Experimente zur Aufgabe haben.

Die zuvor beschriebenen Herausforderungen werden mit dem im Folgenden beschriebenen agenten- und KI-basierten Ansatz

zur Verbesserung der Datensuche adressiert (Abbildung 3.4, blauer Bereich).

Die Simulation durchläuft zyklisch mehrere Phasen, um die Datenbeschreibungen schrittweise zu verbessern (die einzelnen Schritte sind in Abbildung 3.4 als nummerierte Kreise dargestellt). Am Anfang publizieren die Datenanbieter-Agenten ihre initialen Datenbeschreibungen auf dem Marktplatz (0). Dann werden von den Datennutzer-Agenten repräsentative Suchanfragen an den Marktplatz gestellt (1). Der Datennutzer-Agent bewertet die Suchergebnisse (2) und wählt passende Datensätze aus (3). Diese Informationen werden an die Datenanbieter-Agenten zurückgespielt (4), die daraufhin ihre Beschreibung verändern und auf dem Marktplatz aktualisieren (5). Der Datenmarktplatz zeichnet alle Interaktionen auf und nutzt sie für die Verbesserung der Suche.

Neben dem beschriebenen Ansatz werden auch weitere Verbesserungsansätze untersucht, wie die Umsetzung einer KI-basierten Ähnlichkeitssuche als Basis für ein Vorschlagssystem, die KI-unterstützte Zuordnung von Verwendungszwecken zu Datengütern oder die Suche von komplexen Datenbedarfen über mehrere Suchanfragen hinweg.

Die in diesem Abschnitt thematisierte gezielte Verwendung und Nutzung von Daten sowie die Interaktion der Angebots- und Nachfrageseite werden außerdem fortführend im folgenden Abschnitt 3.3 im Rahmen der datengetriebenen Geschäftsmodelle im Kontext von Ökosystemen behandelt.

¹ <https://solr.apache.org/>.

3.3 Datengetriebene Geschäftsmodelle

Dass Daten in der heutigen Zeit eine große Bedeutung zugesprochen wird, ist sicherlich kein Fakt, der für große Überraschungen sorgt. Große Konzerne wie Meta² und LinkedIn³, deren Geschäftsmodelle komplett auf der Verwendung von Daten basieren, sind keine Ausnahme mehr. Solche datengetriebenen Geschäftsmodelle basieren auf der Schlüsselressource Daten und nutzen diese zur Generierung eines Mehrwertes für sich und ihre Kunden (Schüritz et al. 2017; Kühne und Böhmman 2018; Guggenberger et al. 2020a). Da Unternehmen in der heutigen Zeit häufig nicht mehr allein agieren, ist es eine natürliche Reaktion, dass sich sogenannte Ökosysteme bilden. Diese Ökosysteme bieten den Unternehmen den Raum, auf einfache Art und Weise miteinander zu agieren und ihre Dienstleistungen oder Produkte zu vermarkten. Der Vorteil an einem solchen Zusammenschluss ist, dass alle Teilnehmer aufgrund ihrer eigenen Interessen motiviert sind, einen bestmöglichen Beitrag für das Ökosystem zu leisten (Oliveira und Lóscio 2018; Oliveira et al. 2018). Um nun zu verstehen, wie ein Unternehmen sein Geschäftsmodell basierend auf Daten in einem solchen Datenökosystem aufbaut, ist es wichtig zu verstehen, welche Bestandteile von hoher Bedeutung sind und welche Möglichkeiten sich für die Unternehmen bieten an dem Ökosystem teilzunehmen.

Datengetriebene Geschäftsmodelle im Umfeld von Datenökosystemen

Um ein datengetriebenes Geschäftsmodell verstehen zu können, ist es wichtig, zunächst sein Umfeld zu betrachten. Da ein datengetriebenes Geschäftsmodell häufig Daten in unterschiedlichen Formen als Schlüsselressource verwendet, ist es naheliegend, zunächst einen Blick auf Datenökosysteme zu werfen. Nach Oliveira and Lóscio (2018) definiert sich ein Datenökosystem als ein Netzwerk verschiedenster Akteure, die ihre Synergien nutzen, um ihre Ressourcen, in der Regel Daten

oder ähnliche Produkte, miteinander auszutauschen (Oliveira und Lóscio 2018). Bei der Betrachtung einzelner Akteure eines Ökosystems kann festgestellt werden, dass jeder Einzelne über ein Geschäftsmodell verfügen muss, um seine Strategie für die Wertgenerierung definieren zu können. Folglich lässt sich ein datengetriebenes Geschäftsmodell im Umfeld eines Ökosystems als ein Akteur eines Netzwerks (Ökosystems) einordnen, der die Kernressource Daten nutzt (vgl. Abbildung 3.5). Diese Daten kann das jeweilige Unternehmen selbst produzieren, von anderen Unternehmen erhalten und konsumieren und/oder an weitere Akteure vermitteln.

Datengetriebene Geschäftsmodelle können als Geschäftsmodelle bezeichnet werden, bei denen die Verwendung und Weiterverarbeitung von Daten zur Erstellung des Wertversprechens im Fokus liegt. Zur Wertschöpfung dieser Wertversprechen werden insbesondere Datenanalyseverfahren angewendet, um neue Erkenntnisse und Wissen zu generieren.

Ein Datenökosystem besteht im Wesentlichen aus vier Komponenten: Akteure, Rollen, Beziehungen und Ressourcen (Oliveira und Lóscio 2018; Oliveira et al. 2018). Damit ein Unternehmen an einem Ökosystem teilnehmen kann, muss es sich zunächst entscheiden, welche Rolle es in einem Ökosystem einnehmen möchte, da dies grundlegend über die weitere Ausrichtung des Geschäftsmodells entscheidet. Darüber hinaus muss festgelegt werden, wie die Beziehungen zu den anderen Akteuren definiert und welche Ressourcen verwendet werden sollen. Innerhalb dieser Bereiche werden weitere Ausprägungen, die für ein Geschäftsmodell von Bedeutung sind, wie beispielsweise das Leistungsangebot, festgelegt. Durch den Zusammenschluss einer Vielzahl von unterschiedlichen Unternehmen und den unternehmensübergreifenden Datenaustausch ergibt sich schlussendlich ein Ökosystem, in dem wertschöpfende Aktivitäten basierend auf Daten getrieben werden (vgl. erneut Abbildung 3.5).

² <https://about.facebook.com/de/meta/>.

³ https://about.linkedin.com/de-de?trk=homepage-basic_directory_aboutUrl&lr=1.

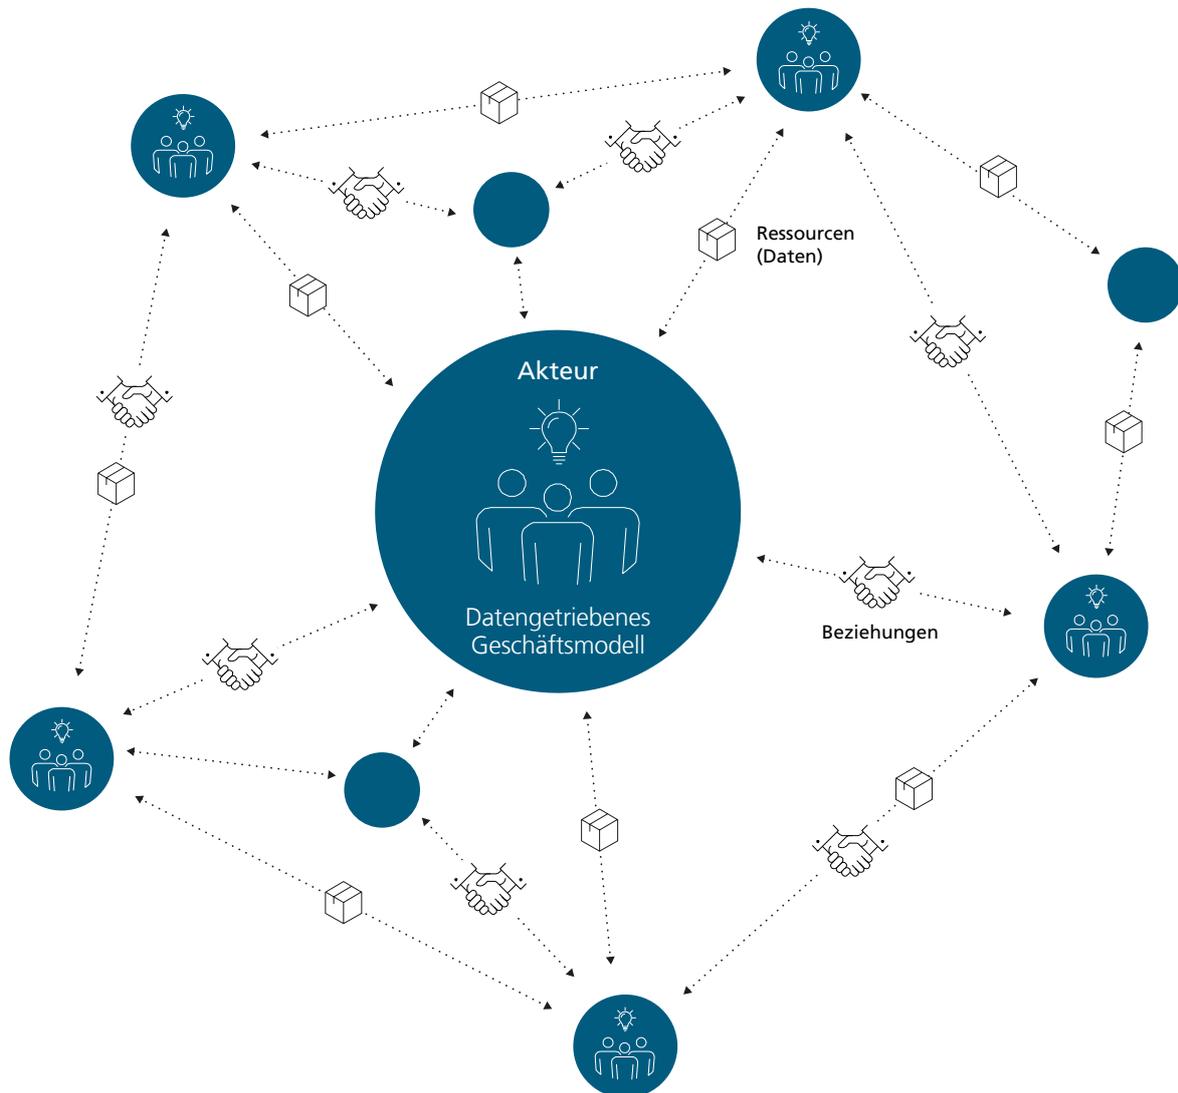


Abbildung 3.5 Akteure und deren datengetriebene Geschäftsmodelle im Ökosystemkontext (eigene Darstellung)

Wie zuvor erwähnt, stellt zu Beginn die Rollenwahl für Unternehmen eine wichtige Entscheidung dar. Hierbei ergeben sich zunächst drei mögliche Rollen, die ein Akteur einnehmen kann: Konsument, Vermittler oder Produzent (Oliveira und Lóscio 2018). Jedoch finden sich in der Praxis viele weitere Ausprägungen dieser Rollen, die oftmals spezifischere Aufgaben für sich definieren. Generell lässt sich feststellen, dass

es mindestens einen Akteur gibt, der die ihm zur Verfügung gestellten Daten oder Dienstleistungen konsumiert, die ein anderer Akteur erzeugt hat. Da jedoch der Austausch zwischen zwei Akteuren häufig geregelt werden muss, findet sich ein Vermittler zwischen den beiden Akteuren wieder, der die notwendige Infrastruktur bereitstellt und auf die Einhaltung der geltenden Vorschriften und Regeln achtet.



Rollen in Ökosystemen

Um die verschiedenen Rollen in einem Ökosystem feingranularer definieren zu können, wurden 64 Anwendungsfälle des Gaia-X Hub Deutschland⁴ (Stand: August 2020) untersucht. Diese Anwendungsfälle wurden ausgewählt, da sie aus unterschiedlichen Branchen stammen und einen umfassenden Einblick in aktuelle datengetriebene Geschäftsmodellarchitekturen und Ökosysteme auf Basis der Gaia-X-Infrastruktur (vgl. Abschnitt 1.2) geben.

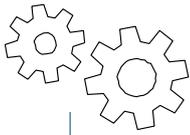
Es wurde herausgearbeitet, welche Rollen in den jeweiligen Anwendungsfällen existieren und welcher Akteur welche spezielle Rolle im Ökosystem einnimmt. Darauf aufbauend wurden Rollenbeschreibungen in Bezug auf die vier Geschäftsmodelldimensionen Wertangebot, Werterzeugung, Wertbereitstellung und Werterfassung angefertigt. Das Wertangebot beschreibt

den übergeordneten Wert oder Nutzen, den die anderen Akteure durch die angebotenen Dienstleistungen oder Produkte erhalten sollen, während die Werterzeugung beschreibt, auf welche Art und Weise die Erstellung dieser Werte erfolgt (Osterwalder und Pigneur 2002). Mit der Wertbereitstellung wird definiert, über welche Kanäle das Wertangebot den anderen Akteuren zugänglich gemacht wird, und mit der Werterfassung, wie mit diesem Erträge erzielt werden können (Azkan et al. 2020a). Insgesamt konnten anhand der durchgeführten Untersuchung acht verschiedene Rollen identifiziert werden, welche, basierend auf den vier Geschäftsmodelldimensionen, in Abbildung 3.6 zusammengefasst dargestellt sind.

Wie in diesem Kapitel ausgeführt, sind Daten für Unternehmen wertvoll und bewegen diese dazu, ihre Geschäftsmodelle darauf zu basieren. Die Bestimmung des Werts von Daten wird daher nachfolgend in Abschnitt 3.4 näher betrachtet.

⁴ <https://www.bmwi.de/Redaktion/DE/Dossier/gaia-x.html>.

Ecosystem Roles



Service Provider

bietet den Akteuren im Ökosystem, meist aufbauend auf den Daten des Data Providers, Dienstleistungen an.

- Das Wertversprechen ist durch die Generierung von Wissen, Handlungsempfehlungen und die Entwicklung von Anwendungen gekennzeichnet.
- Die Gewinnung von Wissen und Handlungsempfehlungen erfolgt insbesondere durch das Management von Daten und die Analyse dieser Daten.
- Um seine Dienste den anderen Akteuren anzubieten, nutzt er APIs oder Cloud-Plattformen oder stellt sie als direkten Download zur Verfügung.
- Für seine Leistungen verlangt er eine Gebühr in Form von Einmalzahlungen, Abonnementverträgen, Pay-per-Use oder leistungsbezogenem Contracting.



Data Trustee

vermittelt zwischen dem Datenanbieter und dem Diensteanbieter, stellt die Verfügbarkeit der Daten sicher.

- Das Wertversprechen zeichnet sich durch die Gewährleistung eines sicheren und rechtskonformen Datenaustausches aus.
- Umsetzung durch Verwaltung der Zugriffsrechte, die Speicherung, Verschlüsselung und die Übermittlung der Daten
- Für die Übertragung der Daten werden Cloud-Lösungen genutzt, auf die die Nutzer des Datentreuhanddienstes Zugriff haben.
- Im Gegenzug erhalten die Datentreuhänder in der Regel feste Beträge für ihre Dienste oder werden nach dem Pay-per-Use-Prinzip bezahlt.



Data-Infrastructure Provider

stellt die IT-Infrastruktur bereit, auf deren Basis die Cloud-Plattformanbieter operieren und sensible Daten austauschen.

- Er garantiert höchstmögliche Sicherheit, Datenhoheit sowie ein dezentrales und interoperables Datenmanagement mit medienbruchfreier Bereitstellung der Daten.
- Er stellt eine auf Standards und Policy-Regeln basierende Infrastruktur bereit, auf der die Einhaltung von regulatorischen Anforderungen an Sicherheitsstandards realisiert wird.
- Bereitgestellt wird sie als Cloud-Lösung.
- Im Fall von GAIA-X wird kein monetärer Gegenwert verlangt.



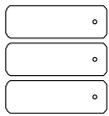
App-Store Provider



stellt eine Austauschplattform bereit, auf der Entwickler ihre Tools anbieten und Dritte diese beziehen können.

- Das Wertversprechen ist dadurch gekennzeichnet, dass Entwickler ihre Anwendungen vermarkten und Dritte sie finden und beziehen können.
- Ermöglicht wird dieses Wertversprechen durch die Schaffung einer Austauschplattform, die in der Regel Such- und Filterfunktionen beinhaltet.
- Der App-Store wird als Cloud-Plattform zur Verfügung gestellt.
- Als Gegenleistung für seine Vermittlungsfunktion erhält der Anbieter i.d.R. eine Transaktionsgebühr für Transaktionen zwischen Entwicklern und Kunden.

Abbildung 3.6: Rollen in Ökosystemen (eigene Darstellung)



Data Provider

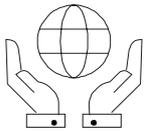
stellt dem Ökosystem Daten oder Metadaten bereit und teilt diese mit anderen Akteuren.

Das Wertversprechen ist durch die Bereitstellung von Daten gekennzeichnet, die von den anderen Akteuren im Ökosystem weiterverwendet werden können.

Die Daten werden mit technischen Hilfsmitteln erfasst, entweder als Hauptprodukt (z. B. Wetterdaten) oder als Nebenprodukt (z. B. Daten zur Überwachung der eigenen Anlagen).

Die Daten werden automatisch zum Service-Anbieter übermittelt (z. B. über Smart-Wearables) oder über APIs, Cloud-Plattformen oder Download-Portale zur Verfügung gestellt.

Es wird ein Mehrwert durch den direkten Verkauf der Daten, durch Prozessoptimierung, Kosteneinsparungen oder Qualitätsverbesserungen aufgrund von Datenanalysen generiert.



Ecosystem Orchestrator

hat das Ökosystem geschaffen durch das Zusammenbringen der Akteure und hat Zugang zu Informationen über das gesamte Ökosystem.

Er stellt sicher, dass alle am Ökosystem beteiligten Akteure die Möglichkeit haben, sich wertschöpfend zu beteiligen und der höchstmögliche gemeinsame Wert geschaffen wird.

Er identifiziert die verschiedenen Rollen im Ökosystem, schafft Verbindungen zwischen ihnen, motiviert sie zur Zusammenarbeit und ergreift ggfs. Maßnahmen zur Kuration des Ökosystems.

Er tritt entweder in direkten Kontakt mit den Akteuren oder modifiziert die vom Ökosystem genutzte Plattform.

Da jener Akteur, welcher die Rolle des Ecosystem Orchestrators einnimmt, i.d.R. auch die Rolle des Cloud-Plattform-Providers innehat, gelten für ihn dieselben Erlösmodelle.



Cloud-Plattform-Provider

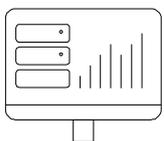
stellt eine Plattform zur Verfügung, mit deren Hilfe die Akteure am Ökosystem teilnehmen und wertschöpfend miteinander interagieren.

Das Wertversprechen umfasst das Zusammenbringen der Akteure auf der Plattform, kann aber auch die Speicherung, Analyse und Anzeige von Daten beinhalten.

Das Wertversprechen wird durch Bereitstellung der erforderlichen Austauschplattform, Anwendungen und Werkzeuge realisiert.

Die Leistungen werden auf Basis einer Cloud-Plattform zur Verfügung gestellt.

Der Anbieter der Cloud-Plattform kann ein Nutzungsentgelt verlangen, wobei jedoch auch Vermittlungsgebühren nicht unüblich sind.



Data-Marketplace Operator

stellt eine Plattform zur Verfügung, mit deren Hilfe Datenanbieter ihre Daten anbieten und Dritte diese konsumieren können.

Das Wertversprechen ist dadurch gekennzeichnet, dass Datenanbieter und -nutzer zusammengebracht werden und Daten frei und sicher bewegt werden können.

Er stellt die vertrauenswürdige Infrastruktur für die gemeinsame Nutzung von Daten bereit, mit der Daten und ihre Metainformationen angeboten und gefunden werden können.

Der Zugang zum Datenmarktplatz kann von den Beteiligten über APIs oder eine Cloud-Plattform erfolgen.

Er erhält in der Regel eine Transaktionsgebühr für erfolgreiche Transaktionen, aber auch eine reine Nutzungsgebühr für die Nutzung des Datenmarktplatzes ist möglich.

Exkurs: Der Einfluss von Big Data auf die Unternehmensperformance

Die Digitalisierung von Unternehmen ist ein wesentlicher Faktor für die Steigerung der Unternehmensperformance. So bietet die Nutzung von Informations- und Kommunikationstechnologien (IKT) nicht nur Möglichkeiten, bereits bekannte Produkte und Dienstleistungen effizienter herzustellen und zu vermarkten, sondern auch Möglichkeiten, neue Produkte und Dienstleistungen und gar gänzlich neue Geschäftsmodelle zu erschaffen.

Auf makroökonomischer Ebene wurde der Einfluss von IKT auf die Produktivität spätestens seit dem 1987 postulierten Solow Paradox diskutiert. Dieses besagt, „man könne das Computerzeitalter überall, nur nicht in den Produktivitätsstatistiken finden“ (Solow, 1987). Oliner & Sichel (2000) war eine der ersten Studien, die einen wirtschaftlich signifikanten Beitrag der IKT zur Produktivität auf Makroebene aufzeigt hat. Der positive Einfluss der Digitalisierung auf die Produktivitätsentwicklung wurde in späteren Studien durch Jorgenson & Stiroh (2000) sowie Byrne et al. (2013) sowie Oliner & Sichel (2000) für die USA und Inklaar et al. (2005) für die USA und vier EU-Länder bestätigt.

Auch auf Unternehmensebene belegen zahlreiche Studien einen positiven Zusammenhang zwischen dem Digitalisierungsgrad eines Unternehmens und der Unternehmensperformance. Ein Überblick dazu findet sich in Draca et al. (2007, 2018), Cardona et al. 2007, Biagi (2013) sowie Schweikl & Obermaier (2020). Erste belastbare empirische Belege auf Unternehmensebene dazu zeigen Brynjolfsson & Hitt (1995), wobei schon in früheren Jahren kleinzahlige Studien und Case Studies positive Effekte benannt haben, siehe Brynjolfsson & Yang (1996).

Aber nicht nur die unternehmensinterne Digitalisierung ist relevant für den Unternehmenserfolg. Auch unternehmensexterne Faktoren, wie die Verfügbarkeit von Breitbandanschlüssen, haben einen Einfluss auf die Unternehmensperformance. Einen Überblick über den Beitrag von Breitbandanschlüssen auf den Unternehmenserfolg geben Bertschek et al. (2015). Gal et al. (2019) zeigen zudem, dass Firmen nicht nur durch firmeninterne Digitalisierungsvorhaben profitieren, sondern auch durch ein digitales Umfeld.

Die insgesamt positiven Effekte von IKT manifestieren sich dabei auf unterschiedliche Weise. Beispielsweise haben Unternehmen mit hoher IKT Nutzung eine höhere Wahrscheinlichkeit, die Zahl ihrer Mitarbeitenden zu vergrößern und eine geringere Wahrscheinlichkeit, aus dem Markt zu treten (van

Reenen et al., 2010). Die Analyse spezifischer IKT von Cappelli (2010) zeigt u.a., dass der Einsatz von Unternehmens-Intranets und Data-Warehousing-Verfahren erhebliche positive Auswirkungen auf den Umsatz pro Beschäftigten hat. Cardona et al. (2013) stellen des Weiteren fest, dass der Zusammenhang zwischen IKT und der Produktivität von Firmen im Zeitverlauf zunimmt. So kommen auch neuere Studien zu dem Ergebnis, dass Investitionen in IKT zu einer höheren Bruttowertschöpfung führen (Dhyne et al., 2018).

Big Data Analysis / Data-Driven Decision Making

Die zunehmende Digitalisierung von Unternehmen führt zu einem großen Anstieg der Datenmengen. Die Daten stammen hierbei aus verschiedenen Quellen: Sowohl firmeninterne Daten von Sensoren, Maschinen oder Enterprise Resource Planning Software, als auch Daten von (potenziellen) Kunden durch Social Media oder Webseiten-Klicks stehen in immer größeren Mengen zur Verfügung. Die Analyse dieser Daten (Big Data Analysis) bietet eine Menge zusätzlicher Informationen für die Entscheidungsfindung und Strategieentwicklung, die zuvor auf explizit gesammelten Daten basierten (Constantiou & Kallinikos, 2015). Als konkrete Wirkungsmechanismen, durch die die Analyse großer Datenmengen einen positiven Einfluss auf die Unternehmensperformance haben kann, werden von Engels & Goecke (2019) Kosteneinsparung, Risikominimierung, Umsatzsteigerungen und veränderte Geschäftsmodelle diskutiert. Die Europäische Kommission ist daher „[...] davon überzeugt, dass die Unternehmen und der öffentliche Sektor in der EU durch die Nutzung von Daten in die Lage versetzt werden können, bessere Entscheidungen zu treffen“ (Europäische Kommission, 2020a).

Auch in der empirischen Literatur wird die Analyse großer Datenmengen mit Vorteilen auf der Unternehmensebene in Verbindung gebracht. Niebel et al. (2019) weisen einen positiven Zusammenhang von Big Data Analysis mit Produktinnovationen in Deutschland nach. Brynjolfsson et al. (2011) zeigen, dass Unternehmen, die datengetriebene Entscheidungen treffen, über einen höheren Marktwert und höhere Eigenkapitalrendite verfügen und produktiver sind. Brynjolfsson & McElheran (2019) finden ebenfalls positive Produktivitätseffekte von datengetriebener Entscheidungsfindung. Basierend auf einem Panel mit börsennotierten US-Unternehmen finden Müller et al. (2018) einen direkten Zusammenhang zwischen Big Data Analysis und Produktivität. Wu et al. (2020) finden zudem eine komplementäre Beziehung von Big Data Analysis und Prozessinnovationen in ihrer Produktivitätswirkung.

3.4 Datenbewertung

Daten nehmen durch ihre Nutzung für bestimmte Zwecke, beispielsweise im Rahmen von datengetriebenen Geschäftsmodellen, einen Wert an. Sie werden damit wirtschaftliche Güter. Daten unterscheiden sich jedoch in mehrerlei Hinsicht von anderen Gütern. Vor diesem Hintergrund wird im Rahmen des IEDS-Projekts die kombinatorische Bewertung von Daten sowie Bewertung von Daten als immaterielle Vermögensgegenstände beleuchtet.

Laut einer Studie von Ocean Tomo (2020) besteht der Marktwert von Unternehmen des S&P 500 zu bis zu 90 % aus immateriellen Vermögenswerten. Für den S&P Europe 350 liegt dieser Wert etwas geringer bei 75 %. Damit lässt sich feststellen, dass der Wert von Unternehmen heute zu einem großen Teil aus nicht-physischen Vermögenswerten besteht.

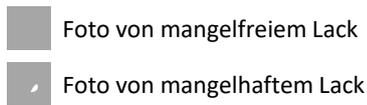
Kombinatorische Datenbewertung

Eine wesentliche Besonderheit von Datensätzen als wirtschaftliches Gut ist, dass sich ihr Wert durch komplexe Substituts- und Komplementärbeziehungen der enthaltenen Datenpunkte ergibt. Dieser muss kombinatorisch mit kostspieligen Verfahren bestimmt werden.

Die Notwendigkeit von kombinatorischer Datenbewertung fußt auf der Beobachtung, dass bei optimaler Kombination wenige Datenpunkte den gleichen oder sogar einen größeren Nutzen als viele Datenpunkte erzielen können. Abbildung 3.7 illustriert dies am Beispiel der Qualitätskontrolle in Lackierereien. Zwei Lackierereien nutzen Fotodaten zur Qualitätskontrolle von lackierten Flächen. Dabei werden Fotos von mangelhaften und mangelfreien Lackstellen genutzt, um einen Algorithmus des maschinellen Lernens zu kalibrieren, der mangelhafte Lackstellen automatisiert erkennen soll. Je höher die Fehlererkennungsrate des Algorithmus ist, desto besser. Es ist grundsätzlich zu erwarten, dass der Grenznutzen eines größer werdenden Foto- bzw. Datensatzes abnimmt. Das bedeutet beispielsweise, dass eine Verdoppelung der Datensatzgröße nicht zu

einer Verdoppelung, sondern zu einer geringeren Verbesserung der Fehlererkennungsrate führt. Entsprechend dürfte das Zusammenfügen der Fotosätze der beiden Lackierereien zwar zu einer Verbesserung führen, nicht jedoch zu einer Verdoppelung. Dagegen kann eine optimale Auswahl von Fotos aus dem Fotosatz beider Lackierereien durchaus höhere Fehlererkennungsraten erzielen, so dass mit Fotosätzen gleicher oder auch kleinerer Größe höhere Fehlererkennungsraten erzielt werden können. Dies ergibt sich dadurch, dass Datenpunkte zueinander substitutive oder komplementäre Beziehungen haben können.

Diese Komplementaritäts- und Substitutsbeziehungen zwischen Datenpunkten lassen sich am Lackierereibeispiel erläutern. Angenommen, es gäbe drei Regelmäßigkeiten in den Daten. Zum einen wären Lackierungen mit der Farbe Rot grundsätzlich mangelanfälliger. Zum anderen wären Lackierungen mit der Farbe Blau weniger mangelanfällig. Weiterhin sind rote und blaue Lackierungen gegenüber anderen Lackierungen mit anderen Farben weniger häufig. Startet man dann bei der Zusammenstellung eines Fotosatzes für die Kalibrierung des Algorithmus mit einer kleinen Zufallsauswahl von Fotos, so dürften Fotos von Lackierungen mit den Farben Rot und Blau zu selten vorkommen, als dass der Algorithmus diesen Zusammenhang vollständig erfassen könnte. Die mit diesen Farben verbundene höhere bzw. niedrigere Mangelanfälligkeit wäre damit nur bedingt feststellbar. Fügt man nun Aufnahmen von roten Lackstellen hinzu, so dürfte der Algorithmus den Zusammenhang von Mangelanfälligkeit und der Farbe Rot erlernen. Das weitere Hinzufügen von Aufnahmen mit roten Lackstellen dürfte dann jedoch keine größeren Verbesserungen der Fehlererkennungsrate mit sich bringen, da die Aufnahmen von roten Lackstellen zueinander substitutiv wirken dürften. Der Algorithmus könnte nichts Neues mehr lernen. Er hat bereits erfasst, dass rote Lackierungen anfälliger für Mängel sind. Demgegenüber dürfte das weitere Hinzufügen von Aufnahmen von blauen Lackstellen die Fehlererkennungsrate weiter steigern, da diese Aufnahmen gegenüber dem bisherigen Fotosatz komplementär wirken dürften. Der Algorithmus könnte in diesem Fall noch dazulernen und zwar, dass blaue Lackstellen weniger anfällig für Mängel sind. In realen Anwendungsfällen und Datensätzen sind solche Substituts- und Komplementaritätsbeziehungen meist wesentlich komplexer und – bei immer größer werdenden Datensätzen – hochdimensional.



Illustrativ

Fotosatz von Lackiererei A



Fotosatz von Lackiererei B



Optimale Auswahl gleicher Größe



Optimale Auswahl kleinerer Größe



Fehlererkennungsraten eines Algorithmus des maschinellen Lernens

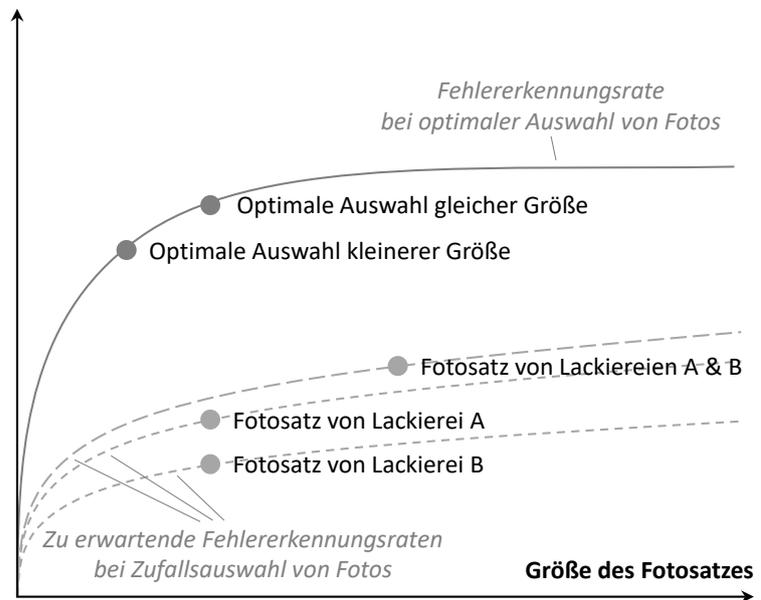


Abbildung 3.7 Beispiel kombinatorischer Datenbewertung (eigene Darstellung)

Die Auswahl optimaler Datenbündel für den größtmöglichen Nutzen ist jedoch sehr rechenaufwendig und im Regelfall mit hohen Kosten verbunden. Im Grunde muss jede denkbare Kombination von Datenpunkten für eine bestimmte Größe des Datenbündels oder für die Einhaltung einer bestimmten Budgetgrenze auf ihren Nutzen getestet werden. Beispielsweise müsste bei der Verwendung von Daten zur Kalibrierung von Algorithmen des maschinellen Lernens für jedes denkbare Datenbündel eine vollständig neue Kalibrierung des Algorithmus erfolgen. Durch die Vielzahl der denkbaren Datenbündel und den hohen Rechenaufwand für die Nutzenbestimmung wird die kombinatorische Bewertung von Daten so zu einem eigenen Kostenfaktor.

In jüngster Zeit wurden jedoch einige technische Innovationen in der akademischen Forschung erzielt, welche die Berücksichtigung kombinatorischer Effekte bei der Bewertung von Daten möglich machen. Im Bereich des maschinellen Lernens werden beispielsweise spieltheoretische Konzepte eingesetzt, bei denen der durchschnittliche Nutzen- bzw. Wertbeitrag einzelner Datenpunkte in Kombination mit anderen Datenpunkten geschätzt wird (Ghorbani und Zou 2019; Kwon et al. 2021). Weiterhin wird versucht, schon bei der erstmaligen Kalibrierung von Algorithmen des maschinellen Lernens auf

einen Datensatz den Wertbeitrag einzelner Datenpunkte bzw. Datenbündel dieses Datensatzes zu bestimmen, beispielsweise mit Methoden des bestärkten Lernens (Yoon et al. 2020). Relevanz haben auch Ansätze zur effizienten Stichprobenziehung aus sehr großen Datenmengen zum Zweck statistischer Schätzungen (Lee und Ng 2020). Auch moderne Verfahren der kombinatorischen Optimierung, die jüngst auch Methoden des maschinellen Lernens einsetzen (Bengio et al. 2018), bieten Möglichkeiten zur effizienten kombinatorischen Bewertung von Daten.

Durch diese neuen Möglichkeiten zur kombinatorischen Datenbewertung können Märkte für Daten effizienter werden. Effiziente Märkte für Daten könnten wiederum starke Anreize zum Erheben, Teilen und Handeln von Daten ergeben. Ein Beispiel: Zwei Datenanbieter haben unterschiedliche Daten. Sind diese Daten für Datennachfrager substitutiv und generieren einen ähnlichen Nutzen, so sind diese Datenanbieter in diesem Marktsegment Konkurrenten. Dies erzeugt Preisdruck und niedrigere Preise für die Käufer der Daten. Sind die Daten für die Datennachfrager komplementär und stiften zusammen einen größeren Nutzen als allein, so sind diese Datenanbieter in diesem Marktsegment mögliche Kooperationspartner. Gemeinsam können sie höhere Preise erzielen als allein und

ZUSAMMENSETZUNG DES MARKTWERTS VON IN GÄNGIGEN AKTIENINDIZES VERTRETENEN UNTERNEHMEN

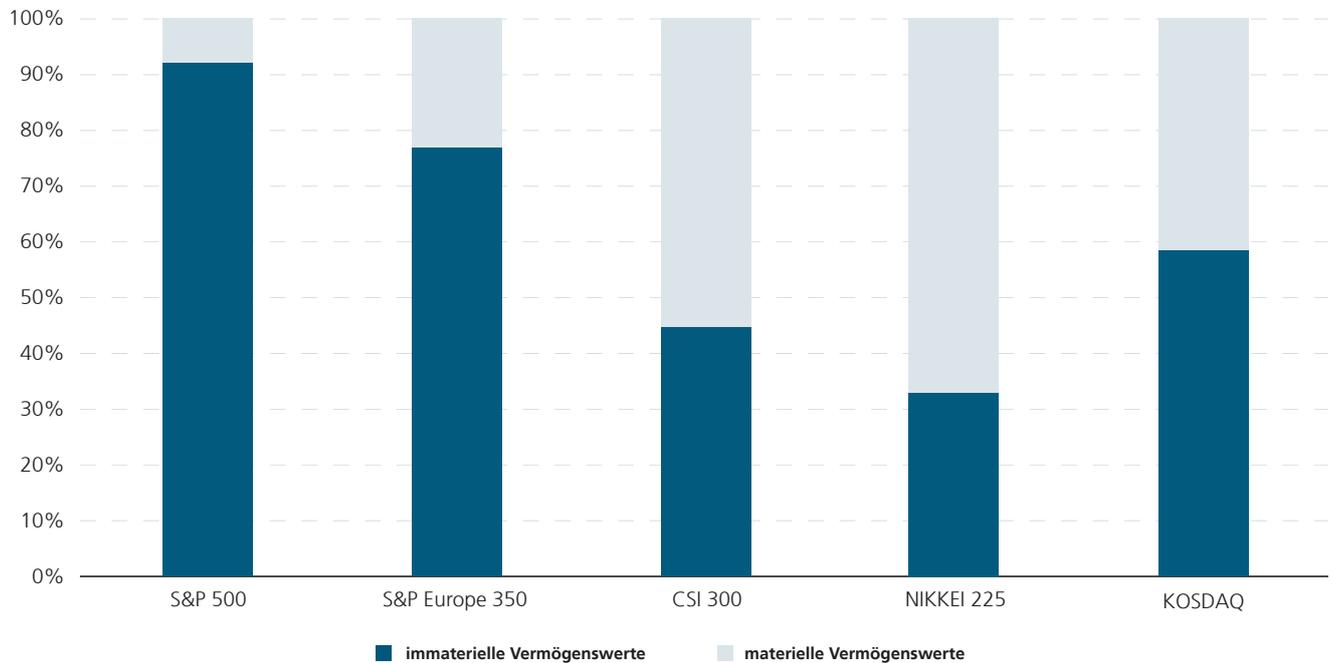


Abbildung 3.8 Verteilung von immateriellen und materiellen Vermögenswerten in gängigen Aktienindizes (eigene Darstellung basierend auf (Ocean Tomo 2020))

neue Anwendungen ermöglichen. Die Grundvoraussetzung solcher Steigerungen der Markteffizienz ist jedoch, dass der kombinatorische Wert von Daten klar bestimmt werden kann. So hat die Lösung dieses technischen Problems eine große mögliche ökonomische Wirkung.

Bewertung von Daten als immaterielle Vermögenswerte

Daten als zentraler Bestandteil der Wertschöpfung könnten als immaterielle Vermögenswerte in der Rechnungslegung behandelt werden. Durch eine bilanzielle Aktivierung immaterieller Vermögenswerte wäre es denkbar, dass Unternehmen die damit verbundenen Gewinnerwartungen in ihre Bilanzen aufnehmen. Dies kann sich positiv auf den Marktwert von Unternehmen auswirken. Dadurch gibt es Anreize, immaterielle Vermögenswerte zu handeln, da durch den Verkauf eine Umsatzsteigerung erreicht werden kann (Singapore Digital 2019). Des Weiteren können, durch die Messung des Einflusses von Daten auf Prozesse, Orientierungspunkte für die Senkung

der Herstellkosten aufgezeigt werden und Daten könnten für die öffentliche oder gemeinschaftliche Nutzung bereitgestellt werden (z. B. innerhalb von Lieferketten) (ebd.). Für eine bilanzielle Aktivierung von Daten bedarf es jedoch einer Bewertung, sollten sie als immaterielle Vermögenswerte definiert werden können.

Immaterielle Vermögenswerte (computerisierte Informationen, geistiges Eigentum und ökonomische Kompetenzen) haben bereits einen großen Anteil am Marktwert von Unternehmen. Gemäß (Ocean Tomo 2020) setzt sich die Marktkapitalisierung von Unternehmen, die im Aktienindex S&P 500 inbegriffen sind, zu 90 % aus immateriellen Vermögenswerten zusammen (vgl. Abbildung 3.8). Bei einem immateriellen Vermögenswert handelt es sich laut den International Accounting Standards (IAS) 38.8 um einen »identifizierbaren, nicht monetären Vermögenswert ohne physische Substanz«. Weitere zentrale Eigenschaften wären gemäß IAS 38.12 die mögliche Abgrenzung zu anderen Vermögenswerten (Identifizierbarkeit), welche durch die Möglichkeit der Einzelveräußerbarkeit bzw. Übertragbarkeit gegeben wäre. Darüber hinaus müssten

immaterielle Vermögenswerte nach IAS 38.13 durch das jeweilige Unternehmen beherrscht werden können, um die Nutzung für Dritte einzuschränken. Immaterielle Vermögenswerte, die bilanziell erfasst werden könnten, wären dabei charakterisiert durch einen klaren Bezug zur Wertschöpfung eines Unternehmens (Kristandl und Bontis 2007). Weiter könnten so Datenbanken und Software (computerisierte Informationen) als immaterielle Vermögenswerte bilanziert werden.

Neben den Anforderungen an immaterielle Vermögenswerte sind auch die Vorgaben zu deren Bilanzierung im Rahmen der International Accounting Standards und des HGB geregelt. Nach den IAS 38.21 wäre ein immaterieller Vermögenswert nur dann in der Bilanz anzusetzen, wenn es zum einen wahrscheinlich ist, dass dem Unternehmen zukünftig der erwartete Nutzen zufließt, und wenn es zum anderen möglich ist, die Anschaffungs- und Herstellungskosten des immateriellen Vermögenswerts verlässlich zu bestimmen. Im Rahmen des HGB wären Vermögensgegenstände nach § 253 Abs. 1 ebenfalls höchstens mit ihren Anschaffungs- oder Herstellungskosten, abzüglich deren Abschreibung, anzusetzen. Im Falle von selbst geschaffenen immateriellen Vermögensgegenständen wären hierfür die bei dessen Entwicklung angefallenen Aufwendungen zu Grunde zu legen (§ 255 Abs. 2a HGB). Somit wären sowohl nach IAS als auch nach HGB kostenorientierte Verfahren zur bilanziellen Erfassung von Daten als immaterielle Vermögenswerte zu betrachten.

Die Übertragbarkeit dieser Überlegungen zu immateriellen Vermögenswerten auf Daten sind nur sehr begrenzt möglich. Dies liegt darin begründet, dass einzelne Daten aus rechtlicher

Sicht weder eigentums- noch besitzfähig sind (vgl. Abschnitt 3.5). Verfügt ein Akteur über Daten, indem dieser beispielsweise das verbundene Speichermedium besitzt, kann dieser auch über die weitere Verwendung der Daten bestimmen. Entscheidend ist dabei die faktische Herrschaft, ohne dass es hierzu eines Ausschließlichkeitsrechts bedarf (Scheufen 2020a). Im Hinblick auf die von den IAS geforderte Beherrschung immaterieller Vermögenswerte könnten so zwar Nutzungsrechte an den Daten vorgegeben und übertragen werden, diese ließen sich allerdings lediglich über enge gesetzliche und vertragliche Zugangsrechte individuell regeln. Ein exklusives Schutzrecht, das dem Schutzzumfang eines immateriellen Schutzrechts (z. B. Patent- oder Urheberrecht) dabei entspricht, ist im Kontext von Daten aber nur bedingt und höchstens für z. B. eine Datenbank, aber nicht für die Daten selbst (d. h. nur die strukturelle, nicht aber die syntaktische oder semantische Ebene) existent (vgl. weiterführend Abschnitt 3.5).

Für die handels- und steuerrechtliche Erfassung von immateriellen Vermögenswerten ist, wie zuvor erwähnt, der Beitrag zur Wertschöpfung von entscheidender Bedeutung. Betrachtet man Daten als computerisierte Informationen, so dürften Informationsmerkmale wie die Zugänglichkeit, die Verwendbarkeit, die Aktualität, der Kontext, die Genauigkeit, die Relevanz und das Vertrauensniveau (Tang et al. 2008) für die Bewertung ihres Wertschöpfungsbeitrags maßgeblich sein. Tabelle 3.1 stellt wesentliche Arten und Quellen von Daten bzw. computerisierte Informationen, wie sie in Unternehmen vorkommen, dar. Diese Informationsarten könnten bewertet werden, um sie bilanziell zu erfassen.

Tabelle 3.1: Wesentliche Datenarten und Datenquellen in Unternehmen (eigene Darstellung basierend auf (Dakova et al. 2018))

Typ	Definition	Beispiele
Intellektuelles Kapital	Humankapital und geistiges Eigentum	Kompetenzen, Prozesse, Image
Wissen	Value in use / Bewertung von Wissen als Handlung	Produktmanagement, Kundenservice, Partnermanagement
Supply-Chain-Daten	Abbildung und Nutzung von Lieferketten	Bestände, Kapazitätsplanung in der Produktion
Geschäftsprozessinformationen	Information als business transformation	Information Lifecycle Management
Entscheidungsunterstützungssysteme	Wertbeitrag zu Entscheidungen	Bayessches Netz



Wie bei allen Vermögenswerten könnte auch der Wertschöpfungsbeitrag bzw. der Wert von Daten sehr wirkungsvoll über einen aktiven Markt für diese Vermögenswerte bemessen werden (Oppenheim et al. 2003). Für immaterielle Vermögensgegenstände mangelt es jedoch häufig an aktiven Märkten. Neben einem solchen marktpreisorientierten Verfahren lassen sich für die Schätzung des Wertschöpfungsbeitrags auch kostenorientierte und nutzungsorientierte Verfahren einsetzen (Laney 2018). Kostenorientierte Verfahren bestimmen den finanziellen Wert auf Grundlage der Herstellungskosten oder Anschaffungskosten von Gütern. Kostenorientierte Verfahren zeichnen sich durch eine geringe Komplexität aus und orientieren sich an physischen Wertschöpfungsketten. Nutzungsorientierte Verfahren bewerten den finanziellen Nutzen über den gesamten Nutzungszeitraum. Dies bringt eine relativ hohe Komplexität mit sich, stellt jedoch die Möglichkeit der Berücksichtigung zukünftiger Wertschöpfung in Aussicht (Zechmann 2018).

Durch eine feingranulare kostenorientierte Bewertung von Daten wird die Basis zur Ermittlung eines Verkaufspreises geschaffen, sodass diese Daten im Falle der Veräußerung Einkommen generieren. Durch die daraus ermittelten Herstellungskosten können diese außerdem gezielt reduziert werden, da deren Zusammensetzung nun bekannt ist. Zudem lassen sich Daten durch eine Bewertung entlang einer Wertschöpfungskette effizient bewirtschaften, indem sie im Falle des Datenaustauschs bestehende Prozesse optimieren können.

Die Bewertung von Daten tangiert, speziell im Hinblick auf die bilanzielle Erfassung, außerdem auch rechtliche Fragestellungen. Der Bereich des Datenrechts, der sich damit noch detaillierter beschäftigt, wird hierzu im nächsten Abschnitt näher vorgestellt.

3.5 Datenrecht

Die Bewirtschaftung im Allgemeinen und das Teilen von Daten im Besonderen erfolgt letztlich immer im Kontext eines (territorialen) Ordnungsrahmens. Damit schließt sich unmittelbar die Frage einer rechtskonformen Nutzung und Verwertung von Daten an. Gerade mit Blick auf innovative (zum Teil KI-unterstützte) datengetriebene Geschäftsmodelle wirft das digitale Zeitalter allerdings Fragen auf, die sich vor dem analogen Entstehungskontext des zivilrechtlichen Ordnungsrahmens bisher nie stellten (Fries und Scheufen 2019; Scheufen 2020b). Auch zur Internalisierung der (wirtschaftlichen) Potenziale von Daten und der (anreizgesteuerten) Bereitschaft der Unternehmen zum Teilen von Daten stellen rechtliche Bedenken und Fragen der Datensicherheit eine wesentliche Hürde dar (Demary et al. 2019; Krotova et al. 2020; Röhl et al. 2021).

Das Arbeitspaket Datenrecht gliedert sich in zwei Bausteine:

- **Rechtsanalyse:** Die Rechtsanalyse skizziert und analysiert den Status quo des rechtlichen Ordnungsrahmens für das Teilen von Daten. Die einzelnen Rechtsbereiche zur Bewirtschaftung von Daten im Allgemeinen und das Teilen von Daten (im Gaia-X-Kontext) im Besonderen werden nicht nur beschrieben, sondern vor dem Hintergrund idealtypischer Anwendungsbeispiele durchdekliniert. Ergänzt wird die rechtliche Analyse durch eine rechtsökonomische Folgebewertung, die bestehende Rechtslücken aufzeigt und hieraus rechtspolitischen Handlungsbedarf ableitet.
- **Bedarfsanalyse:** Die Bedarfsanalyse analysiert im Einzelnen die verschiedenen Hemmnisse für das Teilen von Daten aus wirtschaftlicher, rechtlicher, technischer und organisatorischer Perspektive. Die Bedeutung der rechtlichen Perspektive sowie einzelner Bereiche des Rechts für die Bereitschaft zum Teilen von Daten sollen auf der Basis einer Unternehmensbefragung Orientierung und Leitlinien für eine rechtspolitische Agenda eines Anreizsystems zum Datenaustausch bieten.

Beide Bausteine zeigen in einer gemeinsamen und praxisorientierten Betrachtung den Status quo und die Relevanz unterschiedlicher (zivil-)rechtlicher Normen sowie Lösungsansätze für eine transaktionskostensenkende Umsetzung auf.

Status quo des rechtlichen Ordnungsrahmens

Das Datenrecht ist ein Querschnittsthema, das in allen Bereichen der Datennutzung relevant ist und sich entlang der gesamten Wertschöpfungskette erstreckt. Die rechtskonforme Nutzung von Daten ist dabei vor dem Hintergrund der Unterscheidung zwischen personenbezogenen und nicht-personenbezogenen Daten zu sehen (vgl. Abbildung 3.9). Weisen Daten einen Personenbezug auf – auch wenn von den Daten nur im weiteren Sinne auf Personen geschlossen werden kann (sog. personenbeziehbare Daten) –, so ist in der Regel der Anwendungsbereich der Datenschutz-Grundverordnung (DSGVO) eröffnet (Fries und Scheufen 2019). Damit verbunden ist ein engmaschiger Pflichtenkatalog zur Generierung, Sammlung, Speicherung, Analyse und Verwertung der personenbezogenen Daten, der eine wirtschaftliche Nutzung der Daten jenseits des unmittelbaren Vertragszwecks – und damit auch das Teilen dieser Daten – kaum ermöglicht (Fries und Scheufen 2019). Insbesondere das Recht auf Vergessenwerden (Art. 17 DSGVO) und damit die Notwendigkeit einer potenziellen Löschung von individuellen Daten stellen das Teilen von Daten in der unternehmerischen Praxis vor schwerwiegende Probleme (vgl. Abbildung 3.9) – auch weil die Datensouveränität, d. h. die faktische Herrschaft über die Daten, von einmal geteilten Daten technisch kaum umsetzbar erscheint (Farke et al. 2019).

Während personenbezogene Daten damit einem engen Regulierungsrahmen unterworfen sind, lassen sich für nicht-personenbezogene Daten außerhalb von kartellrechtlichen Schranken oder dem Schutz von Geschäftsgeheimnissen kaum spezifisch regulierende Normen erkennen. Daten sind nicht eigentums- oder besitzfähig i. S. d. §§ 903, 854 BGB und nur im Ausnahmefall durch das Urheberrecht geschützt. Entscheidend für die Nutzungsberechtigung ist indes vielmehr allein die faktische Herrschaft über die Daten – eines echten Ausschließungsrechts bedarf es nicht. Folglich entscheidet der Dateninhaber auch über die Nutzung sowie gegebenenfalls den Transfer einzelner Nutzungsrechte (Scheufen 2020a). So lassen sich Zugangsrechte (z. B. für das Teilen von Daten) neben engen gesetzlichen Möglichkeiten insbesondere durch vertragliche Vereinbarung einräumen.

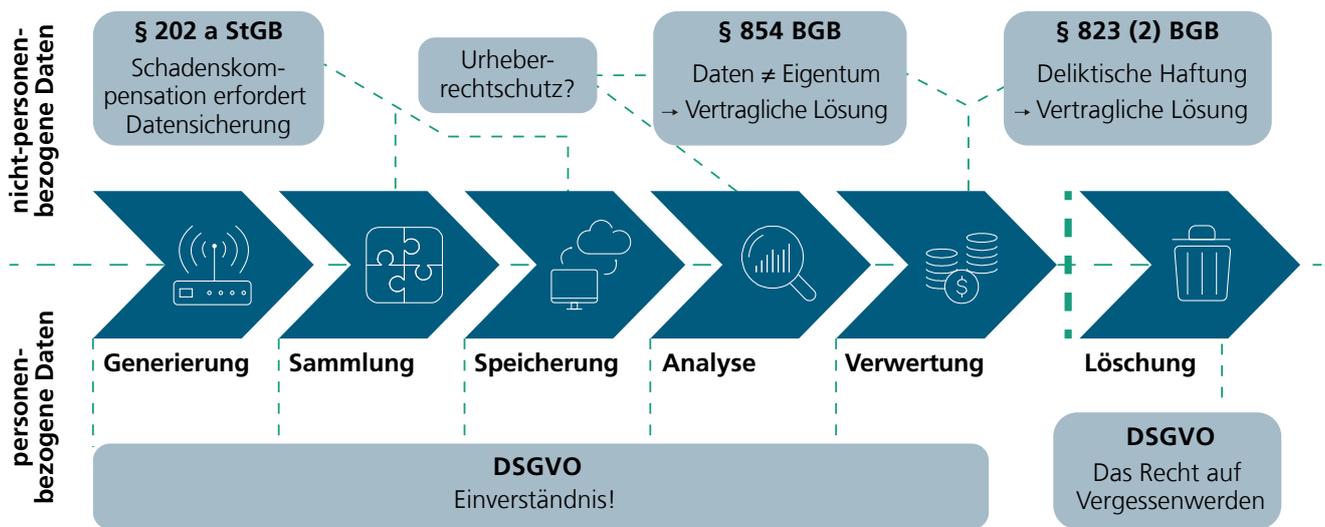


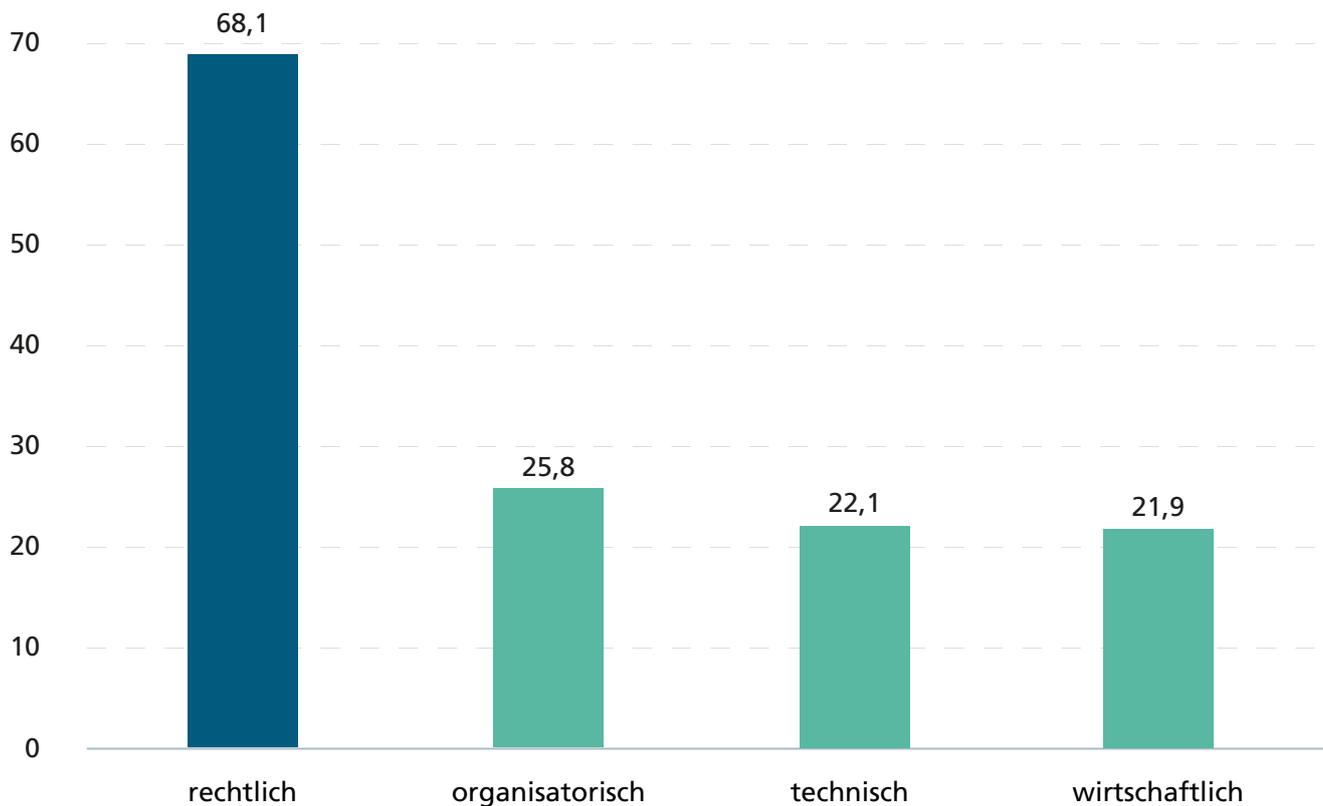
Abbildung 3.9: Recht als Querschnittsthema entlang der Wertschöpfungskette (eigene Darstellung in Anlehnung an Fries und Scheufen 2019)

Die Bewirtschaftung von Daten im Allgemeinen und das Teilen von nicht-personenbezogenen Daten im Besonderen lässt sich vor diesem Hintergrund durch individuelle Verträge oder AGB rechtskonform umsetzen. Bei einer AGB-Ausgestaltung einer Daten(kreuz)-Lizenzierung¹⁴ ist jedoch eine mögliche AGB-Kontrolle durch das Gericht zu berücksichtigen, woraus sich unter Umständen Rechtsunsicherheiten ergeben könnten. Ein solcher Daten-Lizenzvertrag erlaubt neben einer inhaltlichen, zeitlichen oder territorialen Beschränkung der Nutzungsrechte zudem (individuelle) Regelungen zu Haftungsfragen (Rosenkranz und Scheufen 2021). Da Schadensersatzansprüche strafrechtlich an die Datensicherung gekoppelt sind (§ 202a StGB), können auch etwaige Verantwortlichkeiten dieser Datensicherung vertraglich fixiert werden (Fries und Scheufen 2019).

¹⁴ Unter einer Lizenzierung versteht man das Teilen von Daten in eine Richtung, während bei einer Kreuzlizenzierung auch ein multilaterales Teilen in zwei oder mehr Richtungen potenziell möglich ist. Weiterführend hierzu siehe Fritzsche (2020).

Analyse rechtsökonomischer Hemmnisse, Folgen und Bedarfe

Neben dem allgemeinen Überblick über den (zivil-)rechtlichen Ordnungsrahmen zum Bewirtschaften und Teilen von Daten ist ein evidenzbasiertes Wissen über die zentralen wirtschaftlichen, technischen, organisatorischen und rechtlichen Hemmnisse entscheidend, um konkrete Bedarfe und Handlungsempfehlungen für die unternehmerische Praxis ableiten zu können. In diesem Zusammenhang zeigen Studien, dass in Deutschland rechtliche Fragestellungen wesentliche Hürden für die Unternehmen darstellen (Röhl et al. 2021). In internationalen Untersuchungen haben sich neben der datenrechtlichen Regulierung auch datenbezogene und technologische Hemmnisse (Schwierigkeiten der Datennutzung und des Datenaustauschs, fehlende Tools und Kenntnisse für Big-Data-Analysen), wirtschaftliche Hemmnisse (erwartete hohe Kosten für notwendige Investitionen bei unklaren Erträgen) sowie eine generelle Aversion gegen datenbezogene Technologien und Datennutzung, die auch kulturelle Hintergründe haben kann, herausgestellt (Dremel 2017; Moktadir et al. 2019; Mosig et al. 2021; Sun et al. 2016; Malaka und Brown 2015).



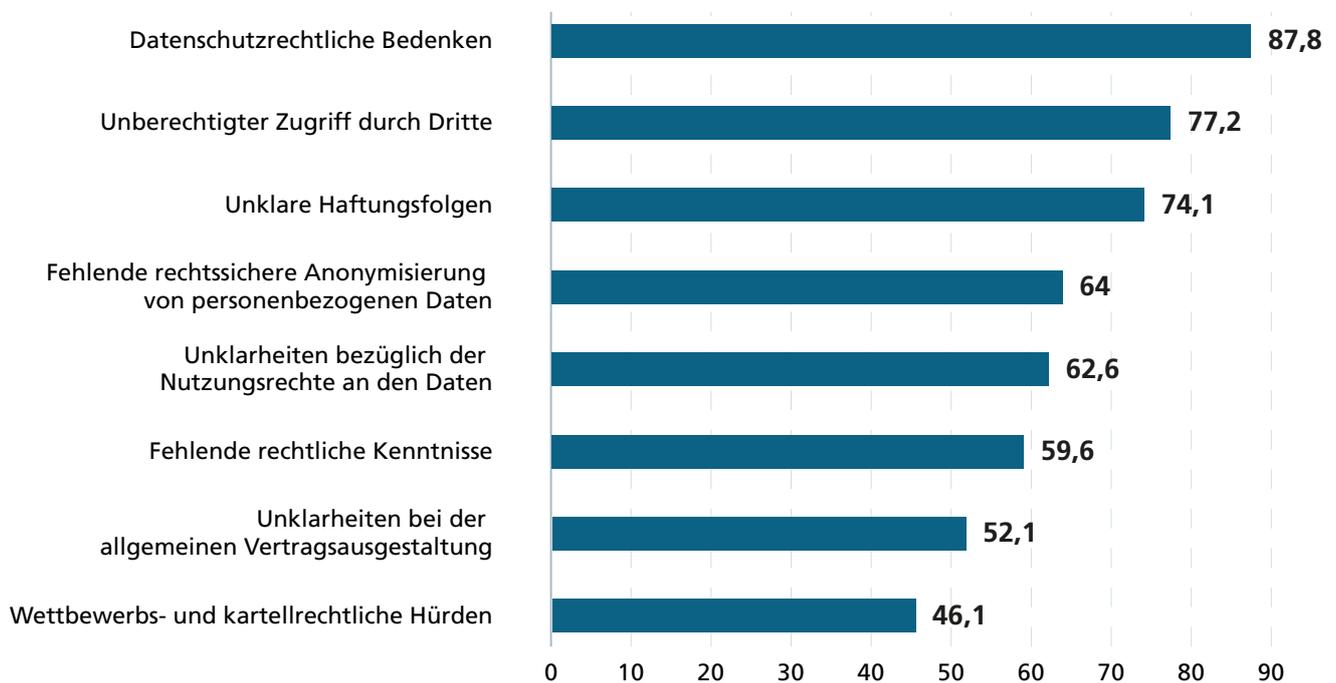
Anteil der Unternehmen in Prozent, n = 1.002

Abbildung 3.10: Arten der Hemmnisse beim Teilen von Daten (Institut der deutschen Wirtschaft, IW Consult)

Auf Basis der in Abschnitt 2.1 vorgestellten Umfrage werden die wirtschaftlichen, rechtlichen, technischen und organisatorischen Hemmnisse beim Teilen von Daten im Einzelnen untersucht. Ausgehend von der Frage »In welchen dieser Bereiche sehen Sie die größten Hemmnisse hinsichtlich des Teilens von Daten?« wird deutlich, dass vor allem rechtliche Hemmnisse einer höheren Bereitschaft zum Teilen von Daten gegenüberstehen. So sehen etwa 68 Prozent der befragten Unternehmen rechtliche Hemmnisse, während mit großem Abstand dahinter organisatorische (25,8 Prozent), technische (22,1 Prozent) und wirtschaftliche (21,9 Prozent) Hürden für das Teilen von Daten gesehen werden (vgl. Abbildung 3.10).

Die besondere Bedeutung von rechtlichen Hemmnissen beim Teilen von Daten motiviert dazu, die verschiedenen Rechtsbereiche und damit unterschiedliche Schwerpunkte für die

Bedarfe der Unternehmen weiterführend zu analysieren. Abbildung 3.11 verdeutlicht, dass für knapp 88 Prozent der befragten Unternehmen vor allem datenschutzrechtliche Bedenken die Bereitschaft zum Teilen von Daten beschränken. Wie bereits diskutiert, sind für personenbezogene Daten die Nutzungsrechte sehr engmaschig reguliert, sodass weitere Nutzungsmöglichkeiten – insbesondere das Teilen von Daten – kaum möglich sind. Vor dem Hintergrund der Befragungsergebnisse scheinen die Unternehmen sich über die engmaschige Regulierung im Klaren zu sein, sodass vermutlich fehlende Kenntnisse zu datenschutzkonformer Verwendung dieser Daten zu dieser Einschätzung führen. In der weiterführenden Analyse zeigt sich, dass es signifikante Unterschiede zwischen kleinen (< 50 Mitarbeiter) und mittelständischen (zwischen 50 und 249 Mitarbeiter) oder großen Unternehmen (mehr als 249 Mitarbeitern) gibt. Ein Grund für diese Unterschiede könnte



Anteil der Unternehmen, die die entsprechenden Items auf die Frage »Inwiefern sind die folgenden rechtlichen Aspekte für Ihr Unternehmen ein Hemmnis, um heute oder in Zukunft Ihre Daten zu teilen?« genannt haben, in Prozent, n = 723.

Abbildung 3.11: Die Bedeutung unterschiedlicher rechtlicher Hemmnisse beim Teilen von Daten (Institut der deutschen Wirtschaft, IW Consult)

darin liegen, dass kleine Unternehmen seltener über eine eigene Rechtsabteilung verfügen und deshalb die rechtlichen Hürden nochmal höher eingeschätzt werden.

Neben datenschutzrechtlichen Bedenken wird von 77 Prozent der Unternehmen der unberechtigte Zugriff durch Dritte als rechtliches Hemmnis angeführt, gefolgt von unklaren Haftungsfolgen (74,1 Prozent), fehlender rechtssicherer Anonymisierung von personenbezogenen Daten (64 Prozent), Unklarheiten bezüglich der Nutzungsrechte an den Daten (62,6 Prozent), fehlenden rechtlichen Kenntnissen (59,6 Prozent) sowie Unklarheiten bei der allgemeinen Vertragsausgestaltung (52,1 Prozent). Für eine Minderheit (46,1 Prozent) stellen wettbewerbs- und kartellrechtliche Hürden ein Problem dar (vgl. Abbildung 3.11).

Folglich zeigen sich nicht nur rechtliche Unsicherheiten mit Blick auf personenbezogene Daten, sondern auch Haftungsfragen sowie vertragliche Fragen, die sich auf die Nutzungsrechte – auch mit Blick auf das Schützen dieser Nutzungsrechte vor unberechtigtem Zugriff durch Dritte – an nicht-personenbezogenen Daten – beziehen. Weiterführende Arbeiten sollten vor diesem Hintergrund auf mögliche dispositive Normen (z. B. ein Datenvertragsrecht mit Musterverträgen, die gezielt das Teilen von Daten betreffen) gerichtet sein, um Datenverträge nicht nur zu beschreiben, sondern für die unternehmerische Praxis anwendbar zu machen. Das nachfolgende Kapitel gibt einen weiteren Ausblick zu weiterführenden Arbeiten innerhalb des Projekts.

4 Ausblick

Die in diesem Whitepaper dargestellten Ergebnisse und Handlungsfelder sind die ersten Schritte in einem ganzheitlichen und umfangreichen Projekt mit dem Ziel, Anreize für Unternehmen zur Teilnahme am Data Sharing und an Datenräumen aufzuzeigen sowie die dazugehörigen Hürden und Herausforderungen zu senken. Darüber hinaus zeigen die wissenschaftlichen Erkenntnisse Möglichkeiten auf, um aktiv und wertschöpfend an der Datenwirtschaft teilzunehmen. Im weiteren Verlauf des Projekts sollen Anreize für, Potenziale von sowie Anforderungen an Data Sharing durch folgende strategische Aktivitäten erforscht werden:

- **Data Economy Readiness:** Die im Whitepaper präsentierten Studienergebnisse bezüglich des Status quo der Datenbewirtschaftung in Deutschland (vgl. Kapitel 2) sollen jährlich evaluiert werden. Im weiteren Verlauf des Projekts werden die Fähigkeit der Datenbewirtschaftung von Unternehmen, ihre Bereitschaft zum Datenteilen und ihre Cloud-Nutzung detaillierter analysiert. Dies geschieht auf Basis der Umfrageergebnisse, die weitere Detailfragen enthalten. Auch ein Vergleich verschiedener Branchen wird erstellt. Es wird außerdem untersucht, inwiefern erfolgreiche und nicht erfolgreiche Unternehmen sich hinsichtlich ihrer Reife der Datenbewirtschaftung sowie der Bereitschaft zum Teilen von Daten unterscheiden. In den kommenden Jahren wird die Umfrage wiederholt. So kann die Entwicklung des Reifegrades der Datenbewirtschaftung, die Rolle der Datenteilung und der Cloud-Nutzung in deutschen Unternehmen regelmäßig nachverfolgt und analysiert werden. Darüber hinaus werden die präsentierten Ansätze zum Monitoring von Gaia-X in die Praxis umgesetzt und die gesammelten Daten analysiert und präsentiert. Nachdem die Auswahl der Indikatoren für das Dashboard weitgehend abgeschlossen ist, werden die Indikatoren in einem nächsten Schritt näher definiert. Dies umfasst beispielsweise die Frequenz der Aktualisierung sowie die konkret verwendeten dargestellten Zahlen und Abgrenzungen. Anschließend werden die automatisierten Verfahren zur Erhebung der Indikatoren programmiert und ausführlich getestet. Dadurch können die Daten in hoher Qualität in ausreichendem Umfang gesammelt und gesichert werden. Dies ermöglicht in einem nächsten Schritt die Aufbereitung und Analyse der Daten. Gleichzeitig wird, um die Daten und die gewonnenen Erkenntnisse optimal darstellen zu können, das Dashboard design, programmiert sowie

implementiert. Ferner finden Survey-Experimente bezüglich der Anreize für das Teilen von Daten statt, um Entwicklungen zu verfolgen und neue Anreiz-Konstellationen zu testen.

- **Datenstrategie und -management** (vgl. Abschnitt 3.2): Im Projekt wurden Vorgehensweisen und Chancen von schlankem und agilem Datenmanagement aufgezeigt, um flexibel und effizient Datenpipelines aufzubauen und dadurch Daten den jeweiligen Konsumenten zur Verfügung zu stellen (Gür 2021). Im weiteren Verlauf soll erforscht werden, wie ein solches Datenmanagement Einfluss auf die Datenstrategie eines Unternehmens nimmt und wie außerdem eine Vorgehensweise zur Entwicklung einer Datenstrategie für das Data Sharing aussehen kann. Darüber hinaus werden Mechanismen und Systeme erforscht, um KI-basiert Datenanbieter und -konsumenten zusammenzuführen. Diese Systeme sollen im weiteren Verlauf weiter evaluiert und prototypisch entwickelt werden.

- **Datengetriebene Geschäftsmodelle** (vgl. Abschnitt 3.3): Anhand einer ausführlichen Recherche wurden verschiedene Geschäftsmodellmuster und Rollen in Datenökosystemen und im Data Sharing aufgezeigt. Im weiteren Verlauf sollen Werkzeuge zur Gestaltung dieser datengetriebenen Geschäftsmodelle entwickelt werden. Dazu werden Visual Inquiry Tools, die intuitive, kollaborative und visuell unterstützte Arbeit an Geschäftsmodellen ermöglichen, entwickelt. Die Tools werden wissenschaftlich über die Methodik der gestaltungsorientierten Forschung entwickelt und basieren sowohl auf Vorarbeiten aus der Literatur als auch auf den Kompetenzen von Experten sowie Anwendern.

Darüber hinaus wird im Rahmen des IEDS-Projekts anhand mikroökonomischer Schätzmethoden der kausale Einfluss von Big Data Analysis auf die Unternehmensperformance untersucht. Da die empirische Literatur bisweilen zu keinem eindeutigen Ergebnis zu diesem Zusammenhang gekommen ist und die bisherigen Studien hauptsächlich Korrelationen aufzeigen, soll die Analyse des kausalen Effektes eine Entscheidungsgrundlage für Unternehmen bieten, um den Nutzen von Big Data Analysis zu evaluieren. Die Ergebnisse können somit einen Beitrag zur Strategiefindung sowie zur Anpassung und zum Ausbau von Geschäftsmodellen leisten.

- **Datenbewertung** (vgl. Abschnitt 3.4): Für die Abwägung von Kosten und Nutzen der kombinatorischen Bewertung von Daten wird im Rahmen des weiteren Projektverlaufs ein ökonomisches Modell entwickelt. Das Modell soll mit experimentellen Daten kalibriert werden können, um die modellierten Zusammenhänge so realistisch wie möglich abzubilden. Darin wird unter anderem die Nutzengenerierung von Datenbündeln dem Aufwand für die Bestimmung optimaler Datenbündel gegenübergestellt. Datennutzern ermöglicht dies beispielsweise die Abschätzung, unter welchen Bedingungen sich die Bestimmung optimaler Datenbündel lohnt, welche Methoden sie dafür einsetzen sollten und welche Zahlungsbereitschaft sie für bestimmte Datenbündel haben sollten. Datenanbietern ermöglicht dies, solche Zusammenhänge zu antizipieren und dies beispielsweise bei der Erhebung von Daten zu berücksichtigen. Eine wesentliche Voraussetzung für die Kalibrierung eines solchen Modells sind Informationen zu den aktuellen technischen Möglichkeiten der kombinatorischen Datenbewertung. Der Status quo dieser Möglichkeiten wird im Rahmen eines Online-Wettbewerbs erhoben. Bezüglich der Bewertung von Daten als immaterielle Vermögenswerte wird im weiteren Verlauf des Projekts erarbeitet, wie Daten als immaterielle Vermögenswerte kostenorientiert bewertet werden könnten. Dies soll Unternehmen unterstützen, Daten als immaterielle Vermögenswerte und als handelbares Gut zu verstehen.

Darauf aufbauend könnte eine Berücksichtigung in der Rechnungslegung erfolgen. Der Schwerpunkt der weiteren Arbeit liegt dabei weniger auf den Details der Rechnungslegung als vielmehr auf einer Bewertung des Wertschöpfungsbeitrags von Daten.

- **Datenrecht** (vgl. Abschnitt 3.5): Im Projekt wird der Status Quo des rechtlichen Ordnungsrahmens analysiert sowie eine rechtsökonomische Folgebewertung durchgeführt. Darüber hinaus soll im Sinne einer Bedarfsanalyse aufgezeigt werden, welche rechtlichen – aber auch wirtschaftlichen, technischen und organisatorischen – Hemmnisse einem Teilen von Daten bisher entgegenstehen. Tiefere Einblicke in die Arten und die Bedeutung verschiedener Hemmnisse können Handlungsbedarfe aufzeigen und Anstoß zu konkreten Handlungsempfehlungen für die politischen Entscheidungsträger sein. Weitere zukünftige Arbeiten des Arbeitspakets Datenrecht richten sich auf die Befähigung von Unternehmen zur rechtskonformen Bewirtschaftung und zum Teilen von Daten. Dies sollen die folgenden zwei wesentlichen Elemente fördern: einen Best-Practice-Katalog, der neben einer einordnenden Ontologie des Datenrechts auch Beispiele vor dem Hintergrund von Use Cases skizziert, um so Orientierung und Navigation für eine rechtskonforme Nutzung von Daten zu sein (1) und einen Vertragsgenerator, d. h. ein interaktiver Werkzeugkoffer zur einfachen Generierung und individuellen Zusammenstellung von Verträgen, der in bestehende Datentransferarchitekturen, wie z. B. Gaia-X, eingebunden werden kann (2).

Durch die zuvor genannten strategischen Aktivitäten sollen Unternehmen Anreize zur Teilnahme am Data Sharing und an Datenräumen aufgezeigt sowie die dazugehörigen Hürden und Herausforderungen gesenkt werden. Um die technologischen, ökonomischen und rechtlichen Aspekte abzudecken, ergibt sich die Kollaboration von fünf Institutionen (vgl. Kapitel 5). Nachfolgend werden die beteiligten Projektpartner vorgestellt.



5 Übersicht über das IEDS-Forschungsprojekt und Projektpartnervorstellung

Das IEDS-Forschungsprojekt zeigt Funktionsweisen der Datenwirtschaft auf und präsentiert außerdem Anreize zum Teilen und zum Austausch von Daten, um an dieser zu partizipieren.

Die vielseitigen und interdisziplinären Themen der Datenwirtschaft machen deutlich, dass die Abdeckung der technologischen, ökonomischen und rechtlichen Aspekte gleichermaßen erforderlich ist. Ausgehend davon ergeben sich als beteiligte Einrichtungen folgende Institutionen, die die notwendige Expertise in einem Kompetenzspektrum vereinen:



Das **Fraunhofer-Institut für Software und Systemtechnik ISST** in Dortmund als Antragssteller nimmt die Rolle der federführenden Einrichtung ein und koordiniert und kontrolliert alle Aktivitäten im Projektverlauf. Das Fraunhofer ISST erforscht seit über 25 Jahren den Wert von und den souveränen Umgang mit Daten. Die Kompetenzen der Abteilung Datenwirtschaft liegen in der Beratung, Konzeption und Umsetzung von Datenstrategien, der Entwicklung von Lösungen für das Datenmanagement, im Aufbau von Datenarchitekturen, in der Bewertung von Datengütern sowie im Bereich Datenanalyse und Künstliche Intelligenz. Durch die angewandte Forschung des Fraunhofer ISST werden neuste wissenschaftliche Erkenntnisse in Kooperation mit Industrieunternehmen erarbeitet und in die Praxis transferiert.



Das **Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO** entwickelt gemeinsam mit Unternehmen, Institutionen und Einrichtungen der öffentlichen Hand Strategien, Geschäftsmodelle und Lösungen für die digitale Transformation. Das Forschungsteam Digital Business Services begleitet Organisationen bei der digitalen Transformation von Geschäftsmodellen, Leistungsangeboten und Geschäftsprozessen. Eine methodische und modellbasierte Zusammenführung von strategisch-fachlichen Aspekten (digitale Geschäftsmodelle, smarte Leistungsangebote, Daten- und Service-Ökosysteme etc.), technischen Aspekten (IT-Architekturen, Internet of Things etc.) für die Konzeption und Umsetzung von Smart Services und Anwendungen der Künstlichen Intelligenz steht im Mittelpunkt der Aktivitäten.





Das **Institut der deutschen Wirtschaft (IW)** ist ein privates, nicht-kommerzielles Forschungsinstitut. Es wird getragen von Arbeitgeberverbänden, Wirtschaftsverbänden und Unternehmen. Auf wissenschaftlicher Grundlage erarbeitet es Analysen und Stellungnahmen zu allen Fragen der Wirtschafts- und Sozialpolitik, des Bildungs- und Ausbildungssystems sowie des Arbeitsmarktes. Kennzeichnend für die IW-Arbeit ist die enge Verknüpfung von wissenschaftlicher Analyse auf Basis fundierter theoretischer Kenntnisse sowie empirischer Forschung und zielgruppenorientierter Öffentlichkeitsarbeit. Das IW besitzt Erfahrungen in der ökonomischen Erforschung

relevanter Themen wie neue datengetriebene Geschäftsmodelle und Plattformen, Herausforderungen bei der digitalen Transformation für Unternehmen, Entwicklung von digitalen Reifegradmodellen sowie Datenökonomie inklusive der kontextabhängigen ökonomischen Analyse des Rechts.

Digitale Technologien verändern unsere Arbeitswelt und haben tiefgreifende Auswirkungen auf Wirtschaft und Gesellschaft. Lang etablierte Methoden und Prozesse werden durch die Digitalisierung in kürzesten Zeiträumen modernisiert und revolutioniert.



Der **Lehrstuhl für Industrielles Informationsmanagement (IIM)** der Fakultät Maschinenbau an der Technischen Universität Dortmund erforscht innovative Konzepte, Verfahren, Architekturen und Lösungen für Geschäfts- und Logistiknetzwerke. Die Arbeiten zeichnen sich durch einen interdisziplinären Zugang zum Forschungsgegenstand an der Nahtstelle von Ingenieurwissenschaften, Betriebswirtschaftslehre und Informatik aus. Besonderer Fokus des Lehrstuhls liegt dabei auf der Grundlagenforschung in den Bereichen Datenmanagement sowie datengetriebene

Geschäftsmodelle. Durch die Anbindung an die Technische Universität bietet der Lehrstuhl zahlreiche Möglichkeiten des Wissenstransfers in die universitäre Ausbildung sowie die Förderung des wissenschaftlichen Nachwuchses. Am Lehrstuhl besteht bereits ein Graduiertenfördernetzwerk als eine Förder- und Weiterbildungsmaßnahme im Hinblick auf die Promotion an der TU Dortmund sowie am Fraunhofer ISST. Zudem liegt eine Beteiligung an der Graduate School of Logistics vor, in der Doktoranden methodisch und inhaltlich zur Promotion geführt werden.



Das **ZEW – Leibniz-Zentrum für Europäische Wirtschaftsforschung** in Mannheim ist ein gemeinnütziges wirtschaftswissenschaftliches Forschungsinstitut in der Rechtsform einer GmbH und Mitglied der Leibniz-Gemeinschaft. Der übergreifende Forschungsleitgedanke am ZEW ist die Analyse und das Design funktionstüchtiger Märkte und Institutionen in Europa. Das ZEW ist offen für interdisziplinäre Kooperationen und Perspektiven. Der Forschungsbereich Digitale Ökonomie untersucht, wie die Digitalisierung wirtschaftliche Prozesse beeinflusst. Er analysiert die Auswirkungen

der Digitalisierung auf Produktion, Innovation und Arbeitswelt sowie die Funktionsweise von digitalen Märkten und Plattformen. Methodisch verfolgt der Forschungsbereich einen empirisch-quantitativen Ansatz. Dabei werden Daten aus eigenen Unternehmensbefragungen und von Internetplattformen sowie makroökonomische Datenbanken mit statistischen und ökonometrischen Verfahren ausgewertet. Mit diesem Profil ist der Bereich für die ökonomische Analyse der Digitalisierung ein zentraler Ansprechpartner in Deutschland.

6 Quellenverzeichnis

- Agahari, Wirawan; Dolci, Riccardo; Reuver, Mark de (2021): Business Model Implications of privacy-preserving technologies in data marketplaces: The case of multi-party computation. In: Twenty-Ninth European Conference on Information Systems (ECIS 2021), S. 1–16.
- Ai, Qingyao; Zhang, Yongfeng; Bi, Keping; Chen, Xu; Croft, W. Bruce (2017): Learning a Hierarchical Embedding Model for Personalized Product Search. In: Noriko Kando (Hg.): Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. SIGIR '17: The 40th International ACM SIGIR conference on research and development in Information Retrieval. Shinjuku Tokyo Japan, 07.08.2017. ACM Special Interest Group on Information Retrieval. New York: ACM (ACM Digital Library), S. 645–654, zuletzt geprüft am 04.11.2021.
- Altamony, Hamzah; Alshurideh, Muhammad Turki; Masa'deh, Ra'ed; Obeidat, Bader (2012): Information Systems for Competitive Advantage: Implementation of an Organisational Strategic Management Process. In: Innovation and Sustainable Competitive Advantage: From Regional Development to World Economies.
- Asch, M.; Moore, T.; Badia, R.; Beck, M.; Beckman, P.; Bidot, T. et al. (2018): Big data and extreme-scale computing: Pathways to Convergence-Toward a shaping strategy for a future software and data ecosystem for scientific inquiry. In: The International Journal of High Performance Computing Applications 32 (4), S. 435–479. Online verfügbar unter <https://journals.sagepub.com/doi/full/10.1177/1094342018778123>, zuletzt geprüft am 30.11.2021.
- Aslett, Matt (2019): DataOps Lays the Foundation for Agility, Security and Transformational Change. Hg. v. 451 Research.
- Azkan, Can; Iggena, Lennart; Gür, Inan; Möller, Frederik; Otto, Boris (2020a): A Taxonomy for Data-Driven Services in Manufacturing Industries. In: Proceedings of the 24th Pacific Asia Conference on Information Systems (PACIS). Dubai, United Arab Emirates.
- Azkan, Can; Iggena, Lennart; Meisel, Lukas; Spiekermann, Markus; Korte, Tobias; Otto, Boris et al. (2020b): DEMAND – Perspektiven der Datenwirtschaft (Use Case Report). Online verfügbar unter <https://www.demand-projekt.de/>.
- Azkan, Can; Iggena, Lennart; Möller, Frederik; Otto, Boris (2021): Towards Design Principles for Data-Driven Services in Industrial Environments. In: Proceedings of the 54th Hawaii International Conference on System Sciences (HICSS). Hawaii, USA.
- Azkan, Can; Möller, Frederik; Meisel, Lukas; Otto, Boris (2020c): SERVICE DOMINANT LOGIC PERSPECTIVE ON DATA ECOSYSTEMS – A CASE STUDY BASED MORPHOLOGY. In: Proceedings of the 28th European Conference on Information Systems (ECIS).
- Badewitz, Wolfgang; Kloker, Simon; Weinhardt, Christof (2020): The Data Provision Game: Researching Revenue Sharing in Collaborative Data Networks, S. 191–200. DOI: 10.1109/CBI49978.2020.00028.

- Bansal, Sharu; Kumar, Dilip (2020): IoT Ecosystem: A Survey on Devices, Gateways, Operating Systems, Middleware and Communication. In: *International Journal of Wireless Information Networks* 27 (3), S. 340–364. Online verfügbar unter <https://link.springer.com/article/10.1007/s10776-020-00483-7>, zuletzt geprüft am 23.12.2021.
- Bengio, Yoshua; Lodi, Andrea; Prouvost, Antoine (2018): Machine Learning for Combinatorial Optimization: a Methodological Tour d'Horizon. Online verfügbar unter <http://arxiv.org/pdf/1811.06128v2>.
- Bertschek, I., Briglauer, W., Hüscherlath, K., Kauf, B., & Niebel, T. (2015). The Economic Impacts of Broadband Internet: A Survey. *Review of Network Economics*, 14(4), 201–227.
- Biagi, F. (2013). ICT and Productivity: A Review of the Literature. Institute for Prospective Technological Studies Digital Economy Working Paper No. 2013/09.
- BMWi: Altmaier: „Wir brauchen eine eigene europäische Dateninfrastruktur!“. Online verfügbar unter <https://www.de.digital/DIGITAL/Redaktion/DE/Meldungen/2019/2019-10-28-altmaier-wir-brauchen-eine-eigene-europaeische-dateninfrastruktur.html>, zuletzt geprüft am 28.10.2021.
- BMWi; BMBF (2019): Das Projekt GAIA-X, Eine vernetzte Dateninfrastruktur als Wiege eines vitalen, europäischen Ökosystems. Berlin.
- Borowiecki, Martin; Pareliussen, Jon; Glocker, Daniela; Kim, Eun Jung; Polder, Michael; Rud, Iryna (2021): The impact of digitalisation on productivity: Firm-level evidence from the Netherlands. In: *OECD Economics Department Working Papers*. DOI: 10.1787/e800ee1d-en.
- Brynjolfsson, Erik; Hitt, Lorin M.; Kim, Heekyung Hellen (2011): Strength in Numbers: How Does Data-Driven Decisionmaking Affect Firm Performance? In: *SSRN Journal*. DOI: 10.2139/ssrn.1819486.
- Brynjolfsson, Erik; McElheran, Kristina (2019): Data in action: data-driven decision making and predictive analytics in US manufacturing. In: *Rotman School of Management Working Paper* (3422397).
- Bundeskanzleramt (2021): Datenstrategie der Bundesregierung. Online verfügbar unter <https://www.bundesregierung.de/breg-de/suche/datenstrategie-der-bundesregierung-1845632>, zuletzt geprüft am 02.12.2021.
- Byrne, D., Oliner, S., & Sichel, D. (2013). Is the Information Technology Revolution Over? *International Productivity Monitor*, 25, 20–36.
- Chapman, Adriane; Simperl, Elena; Koesten, Laura; Konstantinidis, George; Ibáñez, Luis-Daniel; Kacprzak, Emilia; Groth, Paul (2020): Dataset search: a survey. In: *The VLDB Journal* 29 (1), S. 251–272. DOI: 10.1007/s00778-019-00564-x.
- Cirullies, Jan; Schwede, Christian (2021): On-demand Shared Digital Twins – An Information Architectural Model to Create Transparency in Collaborative Supply Networks. In: Tung Bui (Hg.): *Proceedings of the 54th Hawaii International Conference on System Sciences*. Hawaii International Conference on System Sciences: Hawaii International Conference on System Sciences (Proceedings of the Annual Hawaii International Conference on System Sciences).
- Constantiou, Ioanna.; Kallinikos, Jannis (2015): New Games, New Rules: Big Data and the Changing Context of Strategy. In: *Journal of Information Technology* 30 (1), S. 44–57. DOI: 10.1057/jit.2014.17.
- Dahlberg, Tomi; Nokkala, Tiina (2019): Willingness to Share Supply Chain Data in an Ecosystem Governed Platform – An Interview Study. In: *BLED 2019 Proceedings*, S. 619–638. DOI: 10.18690/978-961-286-280-0.33.
- Dakova, J.; Antunes, P.; Chiu, Y. (2018): A Pluralistic Approach to Information Valuation. In: *22nd Pacific Asia Conference on Information Systems*.

- DalleMule, Leandro; Davenport, Thomas H. (2017): What's Your Data Strategy? In: Harvard Business Review.
- Demary, Vera; Fritsch, Manuel; Goecke, Henry; Krotova, Alevtina; Azkan, Can; Krote, Tobias et al. (2019): Readiness Data Economy. Bereitschaft der deutschen Unternehmen für die Teilhabe an der Datenwirtschaft.
- Destatis (2020): Unternehmensregister. Rechtliche Einheiten und abhängig Beschäftigte nach Beschäftigtengrößenklassen und Wirtschaftsabschnitten. Online verfügbar unter <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Unternehmen/Unternehmensregister/Tabellen/unternehmen-beschaeftigtengroessenklassen-wz08.html>, zuletzt geprüft am 25.11.2021.
- Destatis (2021): Jedes dritte deutsche Unternehmen nutzte 2020 Cloud Computing. Online verfügbar unter https://www.destatis.de/DE/Presse/Pressemitteilungen/2021/05/PD21_241_52911.html, zuletzt geprüft am 25.11.2021.
- Dhyne, Emmanuel; Konings, Jozef; van den Bosch, Jeroen; Vanormelingen, Stijn (2018): IT and productivity: A firm level analysis. In: NBB Working Paper No. 346.
- Dremel, Christian (2017): Barriers to the Adoption of Big Data Analytics in the Auto-motive Sector. In: Twenty-third Americas Conference on Information Systems, S. 1–10.
- Draca, M., Martin, R., & Sanchis-Guarner, R. (2018). The evolving role of ICT in the economy. Report by LSE Consulting for Huawei.
- Draca, M., Sadun, R., & van Reenen, J. (2007). Productivity and ICT: A Review of the Evidence. In R. Mansell (Ed.), *The Oxford Handbook of Information and Communication Technologies* (pp. 100–147). Oxford University Press.
- Engels, B., & Goecke, H. (2019). Big Data in Wirtschaft und Wissenschaft: Eine Bestandsaufnahme. *IW-Analysen: Vol. 130*. Institut der Deutschen Wirtschaft Köln Medien GmbH.
- Ereth, Julian (2018): DataOps – Towards a Definition. In: Lernen, Wissen, Daten, Analysen.
- Europäische Kommission (2020a): MITTEILUNG DER KOMMISSION AN DAS EUROPÄISCHE PARLAMENT, DEN RAT, DEN EUROPÄISCHEN WIRTSCHAFTS- UND SOZIALAUSSCHUSS UND DEN AUSSCHUSS DER REGIONEN: Eine europäische Datenstrategie. Online verfügbar unter <https://eur-lex.europa.eu/legal-content/DE/TXT/PDF/?uri=CELEX:52020DC0066&from=DE>, zuletzt geprüft am 02.12.2021.
- Europäische Kommission (2020b): THE EUROPEAN DATA STRATEGY. https://ec.europa.eu/commission/presscorner/detail/en/fs_20_283
- Europäische Kommission (Hg.) (2020c): Vorschlag für eine Verordnung des Europäischen Parlaments und des Rates über europäische Daten-Governance. Online verfügbar unter <https://eur-lex.europa.eu/legal-content/DE/TXT/PDF/?uri=CELEX:52020PC0767&from=EN>, zuletzt aktualisiert am 25.11.2020, zuletzt geprüft am 21.08.2021.
- Europäische Kommission (2021): Data Act & amended rules on the legal protection of databases. Online verfügbar unter https://ec.europa.eu/info/law/better-regulation/have-your-say/initiatives/13045-Data-Act-&-amended-rules-on-the-legal-protection-of-databases_en.
- Europäische Union (2016): Verordnung (EU) 2016/679 des Europäischen Parlaments und des Rates vom 27. April 2016 zum Schutz natürlicher Personen bei der Verarbeitung personenbezogener Daten, zum freien Datenverkehr und zur Aufhebung der Richtlinie 95/46/EG, S. 47–194. DOI: 10.9785/9783504385781-007.
- Experian Ltd. (2019): 2019 Global data management research – Taking control in the digital age.

- Fabritz, Nadine (2015): ICT as an Enabler of Innovation. Evidence from German Micro-data. Munich: ifo Institute - Leibniz Institute for Economic Research at the University of Munich (ifo Working Paper, 195). Online verfügbar unter <https://www.econstor.eu/handle/10419/108762>.
- Farke, Florian; Rensinghoff, Jan; Dürmuth, Markus; Gostomzyk, Tobias (2019): Recht auf Vergessenwerden. Chancen und Grenzen der technischen Umsetzung. In: *Datenschutz und Datensicherheit* 43 (11), S. 681–685.
- Fries, Martin; Scheufen, Marc (2019): Märkte für Maschinendaten: Eine rechtliche und rechtsökonomische Standortbestimmung. In: *MMR* 22 (11), S. 721–726.
- Fruhvirth, Michael; Rachinger, Michael; Prlja, Emina (2020): Discovering Business Models of Data Marketplaces. In: Tung Bui (Hg.): *Proceedings of the 53rd Hawaii International Conference on System Sciences*. Hawaii International Conference on System Sciences: Hawaii International Conference on System Sciences (Proceedings of the Annual Hawaii International Conference on System Sciences).
- GAIA-X (2021): GAIA-X Federation Services. Online verfügbar unter <https://www.gxfs.de/>.
- Gaia-X European Association for Data and Cloud AISBL (2021): Gaia-X Architecture Document. 21.09 Release. Brüssel. Online verfügbar unter https://www.gaia-x.eu/sites/default/files/2021-10/Gaia-X_Architecture_Document_2109.pdf, zuletzt geprüft am 29.11.2021.
- Gal, P., Nicoletti, G., Renault, T., Sorbe, S., & Timiliotis, C. Digitalisation and productivity: In search of the holy grail – Firm-level empirical evidence from EU countries. OECD Economics Department Working Papers, 2019. <https://doi.org/10.1787/18151973>
- Gelhaar, J., Groß, T., Otto, B., 2021. A Taxonomy for Data Ecosystems, in: *Proceedings of the 54th Hawaii International Conference on System Sciences*, Hawaii, USA
- Gelhaar, Joshua; Gürpınar, Tan; Henke, Michael; Otto, Boris (2021b): Towards a taxonomy of incentive mechanisms for data sharing in data ecosystems. In: *PACIS 2021 Proceedings*, S. 1–14.
- Gelhaar, Joshua; Otto, Boris (2020): Challenges in the Emergence of Data Ecosystems. In: *PACIS 2020 Proceedings*, S. 1–14.
- Ghorbani, A.; Zou, J. (2019): Data Shapley: Equitable Valuation of Data for Machine Learning. Online verfügbar unter <http://arxiv.org/pdf/1904.02868v2>.
- Guggenberger, Tobias; Möller, Frederik; Boualouch, Karim; Otto, Boris (2020a): Towards a Unifying Understanding of Digital Business Models. In: *Twenty-Third Pacific Asia Conference on Information Systems*, S. 1–14.
- Guggenberger, Tobias; Möller, Frederik; Haarhaus, Tim; Gür, Inan; Otto, B. (2020b): ECOSYSTEM TYPES IN INFORMATION SYSTEMS. In: *Twenty-Eighth European Conference on Information Systems*.
- Gür, Inan (2021): DataOps for Data Sharing – Challenges and Requirements for interorganizational Data Sharing. Hg. v. Fraunhofer ISST (ISST-Report).
- Gür, Inan; Spiekermann, Markus; Arbter, Michael; Otto, Boris (2021): Data Strategy Development A Taxonomy for Data Strategy Tools and Methodologies in the Economy. In: *Internationale Konferenz Wirtschaftsinformatik*.
- Gurevich, Aleksey; Dey, Srijani (2018): Defining a data strategy. Hg. v. DXC.Technology.
- Hartmann, Philipp Max; Zaki, Mohamed; Feldmann, Niels; Neely, Andy (2016): Capturing value from big data – a taxonomy of data-driven business models used by start-up firms. In: *International Journal of Operations and Production Management* 36 (10), S. 1382–1406.

HARVARD BUSINESS REVIEW ANALYTIC SERVICES, 2019. Critical success factors to achieve a better enterprise data strategy in a multi-cloud environment. Harvard Business Review Analytic Services.

Henderson, Deborah; Earley, Susan (Hg.) (2017): DAMA-DMBOK. Data management body of knowledge. Data Administration Management Association. Second edition. Basking Ridge, New Jersey: Technics Publications.

Hupperz, Marius Johannes; Gür, Inan; Möller, Frederik; and Otto, Boris (2021): What is a Data-Driven Organization? In: AMCIS 2021 Proceedings. 6, Bd. 6.

Hurley, John (2018): WHY YOUR DATA STRATEGY IS YOUR B2B GROWTH STRATEGY. In: Harvard Bus. Rev.

Inklaar, R., O'Mahony, M., & Timmer, M. P. (2005). ICT and Europe's Productivity Performance: Industry-Level Growth Account Comparisons with the United States. *Review of Income and Wealth*, 51(4), 505–536.

International Data Spaces Association (2019): Reference Architecture Model. Version 3.0 April 2019. Berlin. Online verfügbar unter <https://internationaldataspaces.org/download/16630/>, zuletzt geprüft am 29.11.2021.

International Data Spaces Association (2021): BDVA, FIWARE, GAIA-X and IDSA Launch an Alliance to Accelerate Business Transformation in the Data Economy. Brüssel, Berlin. Online verfügbar unter <https://internationaldataspaces.org/download/28798/>, zuletzt geprüft am 30.11.2021.

Jackson, Joshua Conrad; Rand, David; Lewis, Kevin; Norton, Michael I.; Gray, Kurt (2017): Agent-Based Modeling. In: *Social Psychological and Personality Science* 8 (4), S. 387–395. DOI: 10.1177/1948550617691100.

Jorgenson, D., & Stiroh, K. (2000). Raising the Speed Limit: U.S. Economic Growth in the Information Age. *Brookings Papers on Economic Activity*, 31(1), 125–236.

Kacprzak, Emilia; Koesten, Laura; Ibanez, Luis-Daniel; Blount, Tom; Tennison, Jeni; Simperl, Elena (2018): Characterising Dataset Search – An Analysis of Search Logs and Data Requests. In: *SSRN Journal*. DOI: 10.2139/ssrn.3287149.

Koesten, Laura M.; Kacprzak, Emilia; Tennison, Jenifer F. A.; Simperl, Elena (2017): The Trials and Tribulations of Working with Structured Data. In: Gloria Mark (Hg.): *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*. CHI '17: CHI Conference on Human Factors in Computing Systems. Denver Colorado USA, 06 05 2017 11 05 2017. Association for Computing Machinery-Digital Library; ACM Special Interest Group on Computer-Human Interaction. New York, NY: ACM (ACM Digital Library), S. 1277–1289, zuletzt geprüft am 21.10.2021.

Koskinen, Jani; Knaapi-Junnila, Sari; Rantanen, Minna M. (2019): What if we Had Fair, People-Centred Data Economy Ecosystems? In: Institute of Electrical and Electronics Engineers (Hg.): *2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (Smart-World/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)*, S. 329–334. Online verfügbar unter <https://ieeexplore.ieee.org/document/9060350>, zuletzt geprüft am <https://ieeexplore.ieee.org/document/9060350>.

Koutroumpis, Pantelis; Leiponen, Aija; Thomas, Llewellyn D. W. (2017): The (Unfulfilled) Potential of Data Marketplaces. In: *ETLA Working Papers* (53). Online verfügbar unter <http://pub.etla.fi/ETLA-Working-Papers-53.pdf>, zuletzt geprüft am 07.07.2021.

Kristandl, Gerhard; Bontis, Nick (2007): Constructing a definition for intangibles using the resource based view of the firm. In: *Management Decision* 45 (9), S. 1510–1524. DOI: 10.1108/00251740710828744.

Krotova, Alevtina; Mertens, Armin; Scheufen, Marc (2020): Open data and data sharing – An Economic Analysis. In: *IW-Policy Paper*, Bd. 21. Köln.

- Krotova, Alevtina; Rusche, Christian; Spiekermann, Markus (2019): Die ökonomische Bewertung von Daten. Verfahren, Beispiele und Anwendungen = The economic evaluation of data : procedures, examples and applications. Köln: Institut der deutschen Wirtschaft Köln Medien GmbH (IW-Analysen, 129).
- Kühne, Babett; Böhm, Tilo (2018): Requirements for Representing Data-Driven Business Models – Towards Extending the Business Model Canvas. In: Proceedings 24th Americas Conference on Information Systems. New Orleans: USA.
- Kwon, Yongchan; Rivas, Manuel A.; Zou, James (2021): Efficient Computation and Analysis of Distributional Shapley Values. In: International Conference on Artificial Intelligence and Statistics: PMLR, S. 793–801. Online verfügbar unter <http://proceedings.mlr.press/v130/kwon21a/kwon21a.pdf>.
- Laney, Douglas B. (2018): Infonomics. How to monetize, manage, and measure information as an asset for competitive advantage. New York, New York: Bibliomotion Inc. Online verfügbar unter <https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=5023889>.
- Lee, Sokbae; Ng, Serena (2020): An Econometric Perspective on Algorithmic Subsampling. In: *Annu. Rev. Econ.* 12 (1), S. 45–80. DOI: 10.1146/annurev-economics-022720-114138.
- Lenny, L. (2014): 3 reasons why DataOps is essential for big data success — IBM Big Data and Analytics Hub. IBM. Online verfügbar unter <https://www.ibmbigdatahub.com/blog/3-reasons-why-dataops-essential-big-data-success>, zuletzt aktualisiert am 12.08.2021.
- Lusch, Robert F.; Vargo, Stephen L. (2014): *Service-Dominant Logic. Premises, Perspectives, Possibilities*. Cambridge: Cambridge University Press.
- Madera, Karen; Aguilera, Diana Paredes (2020): Deliver business-ready data fast with DataOps. An introduction to the IBM DataOps methodology and practice. Hg. v. IBM.
- Mainali, Kiran; Ehrlinger, Lisa; Matskin, Mihhail; Himmelbauer, Johannes (2021): Discovering DataOps: A Comprehensive Review of Definitions, Use Cases, and Tools. In: *DATA ANALYTICS 2021 : The Tenth International Conference on Data Analytics*.
- Malaka, Iman; Brown, Irwin (2015): Challenges to the Organisational Adoption of Big Data Analytics: A Case Study in the South African Telecommunications Industry. In: *Proceedings of the 2015 Annual Research Conference on South African Institute of Computer Scientists and Information Technologists*.
- Mazhelis, Oleksiy; Luoma, Eetu; Warma, Henna (2012): Defining an Internet-of-Things Ecosystem. In: Sergey Andreev, S. Balandin und Yevgeni Koucheryavy (Hg.): *Internet of Things, Smart Spaces, and Next Generation Networking*. 12th International Conference, NEW2AN 2012, and 5th Conference, ruSMART 2012, St. Petersburg, Russia, August 27-29, 2012. Proceedings. Berlin, Heidelberg: Springer-Verlag, S. 1–14. Online verfügbar unter https://link.springer.com/chapter/10.1007/978-3-642-32686-8_1, zuletzt geprüft am 30.11.2021.
- Mazzei, Matthew J.; Noble, David (2017): Big data dreams: A framework for corporate strategy. In: *Business Horizons* 60 (3), S. 405–414. DOI: 10.1016/j.bushor.2017.01.010.
- Mielli, Fabio; Bulanda, Nicole (2019): Digital Transformation: Why Projects Fail, Potential Best Practices and Successful Initiatives. In: 2019 IEEE-IAS/PCA Cement Industry Conference (IAS/PCA). 2019 IEEE-IAS/PCA Cement Industry Conference (IAS/PCA). St Louis, MO, USA: IEEE, S. 1–6.
- Mildebrath, Hendrik (2021): Data Governance Act. Briefing – EU Legislation in Progress. Online verfügbar unter [https://www.europarl.europa.eu/RegData/etudes/BRIE/2021/690674/EPRS_BRI\(2021\)690674_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/BRIE/2021/690674/EPRS_BRI(2021)690674_EN.pdf), zuletzt aktualisiert am 06.2021, zuletzt geprüft am 21.08.2021.

Moktadir, Md. Abdul; Ali, Syed Mithun; Paul, Sanjoy Kumar; Shukla, Nagesh (2019): Barriers to Big Data Analytics in Manufacturing Supply Chains: A Case Study from Bangladesh. In: *Computers & Industrial Engineering* 128, S. 1063–1075.

Mosig, Tim; Lehmann, Claudia; Neyer, Anne-Katrin (2021): Data-Driven Business Model Innovation. About Barriers and New Perspectives. In: *International Journal of Innovation and Technology Management* (02), 2040017-1-20400174-16.

Mosley, Mark; Brackett, Michael; Earley, Susan (Hg.) (2010): *The DAMA guide to the data management body of knowledge. (DAMA-DMBOK guide). First edition.* Brad-ley Beach, NJ: Technics Publications LLC.

Müller, Oliver; Fay, Maria; vom Brocke, Jan (2018): The effect of big data and analytics on firm performance. In: *Journal of management information systems*.

Nexla (2018): *The definitive Data Operations Report.* Nexla Inc.

Nexla Inc. (2018): *The Definitive Data Operations Report.*

Niebel, Thomas; Rasel, Fabienne; Viète, Steffen (2019): BIG data – BIG gains? Understanding the link between big data analytics and innovation. In: *Economics of Innovation and New Technology* 28 (3), S. 296–316. DOI: 10.1080/10438599.2018.1493075.

Ocean Tomo (2020): *Intangible Asset Market Value Study.*

Oliner, S., & Sichel, D. (2000). The Resurgence of Growth in the Late 1990s: Is Information Technology the Story? *Journal of Economic Perspectives*, 14(4), 3–22.

Oliner, S., & Sichel, D. (2002). Information Technology and Productivity: Where are we now and Where are we Going? *Economic Review*, Q3, 15–44.

Oliveira, Marcelo Iury S.; Lóscio, Bernadette Farias (2018): What is a data ecosystem? In: Marijn Janssen, Soon Ae Chun und Vishanth Weerakkody (Hg.): *Proceedings of the 19th Annual International Conference on Digital Government Research Governance in the Data Age – dgo '18. the 19th Annual International Conference.* Delft, The Netherlands, 30.05.2018 - 01.06.2018. New York, New York, USA: ACM Press, S. 1–9.

Oliveira, Marcelo Iury S.; Oliveira, Lairson Emanuel R. A.; Batista, Marlos G. Ribeiro; Lóscio, Bernadette Farias (2018): Towards a meta-model for data ecosystems. In: *dg.o '18: dg.o 2018: Proceedings of the 19th Annual International Conference on Digital Government Research*, May 30-June 1, 2018, Delft, Netherlands Anneke Zuiderwijk and Charles C. Hinnant (Eds.). ACM, New York, NY, USA, 10 pages., S. 1–10. DOI: 10.1145/3209281.3209333.

Oppenheim, Charles; Stenson, Joan; Wilson, Richard M. S. (2003): Studies on Information as an Asset I: Definitions. In: *Journal of Information Science* 29 (3), S. 159–166. DOI: 10.1177/01655515030293003.

Osterwalder, Alexander; Pigneur, Yves (2002): An e-Business Model Ontology for Modeling e-Business. In: *Proceedings of the 15th Bled Electronic Commerce Conference.* Bled, Slovenia.

Otto, B. (2011): A MORPHOLOGY OF THE ORGANISATION OF DATA GOVERNANCE. In: *ECIS 2011.*

Otto, Boris; Österle, Hubert (2016): *Corporate Data Quality. Voraussetzung erfolgreicher Geschäftsmodelle.* Berlin: Springer Gabler.

Otto, Boris; Rubina, Alina; Eitel, Andreas; Teuscher, Andreas; Schleimer, Anna Maria; Lange, Christoph et al. (2021): *Gaia-X and IDS.* Hg. v. International Data Spaces Association. Dortmund. Online verfügbar unter <https://internationaldataspaces.org/download/19016/>, zuletzt geprüft am 13.12.2021.

Pandit, Harshvardhan J.; O'Sullivan, Declan; Lewis, Dave (2018): *GDPR Data Interoperability Model.*

- Parvinen, Petri; Pöyry, Essi; Gustafsson, Robin; Laitila, Miikka; Rossi, Matti (2020): Advancing Data Monetization and the Creation of Data-based Business Models. In: *Communications of the Association for Information Systems* 47, S. 25–49. DOI: 10.17705/1CAIS.04702.
- Pentek, Tobias; Legner, Christine; Otto, Boris (2017): Towards a reference model for data management in the digital economy. In: *Proceedings of the 12th International Conference on Design Science Research in Information Systems and Technology*.
- Richter, Heiko; Slowinski, Peter R. (2019): The Data Sharing Economy: On the Emergence of New Intermediaries. In: *IIC – International Review of Intellectual Property and Competition Law* 50, S. 4–29. DOI: 10.1007/s40319-018-00777-7.
- Röhl, Klaus-Heiner / Bolwin, Lennart / Hüttl, Paula, 2021, Datenwirtschaft in Deutschland. Wo stehen die Unternehmen in der Datennutzung und was sind ihre größten Hemmnisse?, Gutachten im Auftrag des Bundesverbands der Deutschen Industrie e.V. (BDI), KölnOnline verfügbar unter <https://www.iwkoeln.de/studien/klaus-heiner-roehl-lennart-bolwin-wo-stehen-die-unternehmen-in-der-datennutzung-und-was-sind-ihre-groessten-hemmnisse.html>.
- Rosenkranz, Frank; Scheufen, Marc (2021): Rechtliche Rahmenbedingungen der Lizenzierung von nicht-personenbezogenen Daten. IGEDI Kolloquium. Ruhr-Universität Bochum. Bochum, 06.12.2021.
- Scheufen, Marc (2020a): *Angewandte Mikroökonomie und Wirtschaftspolitik: Mit einer Einführung in die ökonomische Analyse des Rechts*. 2. Aufl. Wiesbaden: Springer.
- Scheufen, Marc (2020b): Urheberrechtliche Fragen der KI. In: Andreas Leupold, Andreas Wiebe und Silke Glossner (Hg.): *IT-Recht. Recht, Wirtschaft und Technik der digitalen Transformation*. 4. Aufl. München: C.H.Beck, S. 1033–1039.
- Schüritz, Ronny; Seebacher, Stefan; Dorner, Rebecca (2017): Capturing Value from Data: Revenue Models for Data-Driven Services. In: *Proceedings of the 50th Hawaii International Conference on System Sciences*. Hawaii, S. 5348–5357.
- Schweikl, S., & Obermaier, R. (2020). Lessons from three decades of IT productivity research: towards a better understanding of IT-induced productivity effects. *Management Review Quarterly*. 70(4), 461-507.
- Singapore Digital (2019): *Guide to Data Valuation for Data Sharing*.
- Solow, R. M. (1987). We'd Better Watch Out. *New York Times Book Review*, 36.
- Sparapani, Jason (2019): *DataOps and the future of data management*. Hg. v. MIT Technology Review Insights.
- Spiekermann, Markus (2019): Data Marketplaces: Trends and Monetisation of Data Goods. In: *Intereconomics* 54 (4), S. 208–216. DOI: 10.1007/s10272-019-0826-z.
- Spiezia, Vincenzo (2011): Are ICT Users More Innovative? In: *OECD Journal: Economic Studies* 2011 (1), S. 1–21. DOI: 10.1787/eco_studies-2011-5kg2d2hkn6vg.
- Statista: Marktanteile der führenden Unternehmen am Umsatz im Bereich Cloud Computing weltweit von Juli 2018 bis Juni 2019. Online verfügbar unter <https://de.statista.com/statistik/daten/studie/150979/umfrage/marktanteile-der-fuehrenden-unternehmen-im-bereich-cloud-computing/>, zuletzt geprüft am 28.11.2021.
- Sun, Shiwei; Cegielski, Casey G.; Jia, Lin; Halla, Dianne J. (2016): Understanding the Factors Affecting the Organizational Adoption of Big Data. In: *Journal of Computer Information Systems*, S. 193–203.
- Susha, Iryna; Grönlund, Åke; van Tulder, Rob (2019): Data driven social partnerships: Exploring an emergent trend in search of research challenges and questions. In: *Government Information Quarterly* 36 (1), S. 112–128. DOI: 10.1016/j.giq.2018.11.002.

Susha, Iryna; Janssen, Marijn; Verhulst, Stefaan (2017): Data Collaboratives as a New Frontier of Cross-Sector Partnerships in the Age of Open Data: Taxonomy Development. In: Proceedings of the 50th Hawaii International Conference on System Sciences. Hawaii, S. 2691–2700.

Syverson, Chad (2011): What Determines Productivity? In: Journal of Economic Literature 49 (2), S. 326–365. DOI: 10.1257/jel.49.2.326.

Tang, Llewellyn C.M.; Zhao, Yuyang; Austin, Simon; Darlington, Mansur; Culley, Steve (2008): A characteristic based information evaluation model. In: Katsumi Tanaka (Hg.): Proceedings of the 2nd ACM workshop on Information credibility on the web. Proceeding of the 2nd ACM workshop. Napa Valley, California, USA, 10/30/2008 – 10/30/2008. Association for Computing Machinery; ACM Special Interest Group on Hypertext, Hypermedia, and Web; ACM Special Interest Group on Information Retrieval. New York, NY: ACM (ACM Conferences), S. 89.

van Reenen, J., Bloom, N., Draca, M., Kretschmer, T., & Sadun, R. (2010). The Economic Impact of ICT. Centre for Economic Performance, London School of Economics.

Vargo, Stephen L.; Akaka, Melissa Achpru; Vaughan, Claudia M. (2017): Conceptualizing Value: A Service-ecosystem View. In: Journal of Creating Value 3 (2), S. 1–8. Online verfügbar unter <https://journals.sagepub.com/doi/10.1177/2394964317732861>, zuletzt geprüft am 23.12.2021.

Wei, Bifan; Liu, Jun; Zheng, Qinghua; Zhang, Wei; Fu, Xiaoyu; Feng, Boqin (2013): A survey of faceted search. In: Journal of Web Engineering Volume 12 (1-2), S. 41–64. DOI: 10.5555/2481562.2481564.

Wilberg, Julian; Kalla, Tobias; Fetscher, Manuel; Rimböck, Franz; Hollauer, Christoph; Omer, Mayada (2018): »Development of a Use Phase Data Strategy for Connected Products: A Case Study in Industry«. Online verfügbar unter <https://ieeexplore.ieee.org/document/8481828>.

Wong, Tracey Y.T.; Peko, Gabrielle; Sundaram, David; Piramuthu, Selwyn (2016): Mobile environments and innovation co-creation processes & ecosystems. In: Information & Management 53 (3), S. 336–344. DOI: 10.1016/j.im.2015.09.005.

Wu, Lynn; Hitt, Lorin M.; Lou, Bowen (2020): Data analytics, innovation, and firm productivity. In: Management Science, 66(5), 2017-2039.

Yoon, Jinsung; Arik, Sercann; Pfister, Thomas (2020): Data Valuation using Reinforcement Learning. In: Proceedings of the 37th International Conference on Machine Learning 119, S. 10842–11085.

Zechmann, Andreas (2018): Nutzungsbasierte Datenbewertung. Entwicklung und Anwendung eines Konzepts zur finanziellen Bewertung von Datenvermögenswerten auf Basis des AHP. Berlin: epubli.



Impressum

1. Auflage, März 2022

Herausgeber

Fraunhofer Institut für Software und Systemtechnik ISST
Emil-Figge-Straße 91
44227 Dortmund

Autoren

Fraunhofer-Institut für Software- und Systemtechnik ISST
Dr.-Ing. Can Azkan
Inan Gür
Marius Hupperz
Joshua Gelhaar
Anna Gieß
Tobias Groß

Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO

Sandra Frings
Dr.-Ing. Holger Kett
Damian Kutzias
Oliver Strauß

Institut der deutschen Wirtschaft

Jan Büchel
Dr. Vera Demary
Barbara Engels
Dr. Henry Goecke
Dr. Armin Mertens
Dr. Klaus-Heiner Röhl
Dr. Christian Rusche
Dr. Marc Scheufen
Bjame Schröder

Technische Universität Dortmund

Valentin Dahms
Ilka Jussen
Dr.-Ing. Frederik Möller
Julia Schweihoff

ZEW – Leibniz-Zentrum für Europäische Wirtschaftsforschung

Raphaela Andres
Dr. Daniel Erdsiek
Dr. Thomas Niebel
Dr. Dominik Rehse
Vincent Rost
Johannes Walter
Sebastian Valet

Satz und Layout

Elisa Kadelka

© Fraunhofer-Gesellschaft e.V., 2022

Die Originalfassung der Publikation ist verfügbar unter
www.ieds-projekt.de

Dieses Forschungs- und Entwicklungsprojekt wird durch das
Bundesministerium für Bildung und Forschung (BMBF) geför-
dert und betreut. Die Verantwortung für den Inhalt dieser
Veröffentlichung liegt bei den Autoren.

GEFÖRDERT VOM



**Bundesministerium
für Bildung
und Forschung**



Kontakt

Dr.-Ing. Can Azkan
Tel. +49 231 976770
pmo@ieds-projekt.de

Fraunhofer-Institut für Software- und
Systemtechnik ISST
Emil-Figge-Str. 91
44227 Dortmund
www.isst.fraunhofer.de