



Hochschulforum
Digitalisierung

NR. 47 / AUGUST 2019

Future Skills: Ein Framework für Data Literacy

Katharina Schüller / Paulina Busch / Carina Hindinger

NR. 47 / AUGUST 2019

Future Skills: Ein Framework für Data Literacy

Kompetenzrahmen und Forschungsbericht

Autorinnen

Katharina Schüller, STAT-UP / Paulina Busch, STAT-UP /
Carina Hindinger, STAT-UP

Inhalt

Inhalt	2
Abbildungs- und Tabellen-verzeichnis	5
Das Hochschulforum Digitalisierung	8
Kapitel 1: Zusammenfassung	10
1.1 Management Summary	10
1.2 Aufbau des Arbeitspapiers	11
1.3 Abgrenzung und Bezug zum zweiten Arbeitspapier der Studie	12
Kapitel 2: Hintergrund und Zielsetzung	14
2.1 Herausforderungen durch Digitalisierung und Datafizierung	14
2.2 Ziele der vorliegenden Studie	15
2.3 Präzisierung des Begriffs „Data Literacy“	15
2.3.1 Data Literacy als Schlüsselkompetenz der 21. Jahrhunderts	16
2.3.2 Mögliche Zwecke von Data Literacy	16
2.3.3 Abgrenzung des Begriffs	16
2.4 Anforderungen an Kompetenzrahmen und Testinstrumente	17
2.4.1 Anforderungen an Mess- und Testinstrumente für Data Literacy	17
Kapitel 3: Herleitung eines Kompetenzrahmens	20
3.1 Vom Aufgabenverständnis zur Kompetenzdefinition	20
3.1.1 Wertschöpfung aus Daten als kompetenzdefinierende Aufgabe	21
3.1.2 Einordnung und Abgrenzung der Kompetenzbegriffe	23
3.2 Haltung als Kompetenz	26
3.3 Ausblick: Ableitung überprüfbarer Lernziele	27
3.4 Didaktische Umsetzungen in anderen Disziplinen	28
3.5 Verortung in der Literatur	29
Kapitel 4: Darstellung des Kompetenzrahmens	33
4.1 Intention und Einsatzmöglichkeit	33
4.2 Gliederungsebenen des Kompetenzrahmens	33
4.3 Von der Kompetenzdefinition zum Kompetenzrahmen	34
4.4 Beispiel einer Kompetenz im Detail	37
Kapitel 5: Messung und Testung von Data Literacy	41
5.1 Einordnung der Mess- und Testinstrumente	41
5.2 Ergebnisse der Literaturanalyse	42

3

5.2.1 Objektive Testverfahren: Multiple-Choice-Tests	43
5.2.2 Interpretative Testverfahren: Rubriken/Bewertungsschemata zu Studienarbeiten/Essays	44
5.2.3 Vom einfachen Test zu multiplen Methoden	45
Kapitel 6: Reflexion und Ausblick	47
6.1 Diskussion mit Fachexpert*innen, Hochschulprofessor*innen und Führungskräften	47
6.1.1 Veränderte Bedeutung von Data Literacy	47
6.1.2 Haltung als Kompetenzdimension	48
6.1.3 Messung von Data Literacy	49
6.2 Ausblick auf Lernziele und Qualifikationsniveaus	50
6.3 Ausblick auf die Testentwicklung	50
6.3.1 Beispielaufgabe zu den Kompetenzen D.1 und E.1	51
6.3.2 Beispielaufgabe zusätzlich zur Kompetenz C.3	51
Anhang A: Fallstudien	53
A.1 Medizin: Diagnostik	55
A.1.1 Fragestellung	55
A.1.2 Vorgehen der Anwender*innen und benötigte Kompetenzen	55
A.1.3 Vorgehen der Expert*innen und benötigte Kompetenzen	57
A.1.4 Ergebnis	59
A.2 Ingenieurswissenschaften: Produktionsüberwachung	61
A.2.1 Fragestellung	61
A.2.2 Vorgehen des oder der Anwender*in und benötigte Kompetenzen	61
A.2.3 Vorgehen der Expert*innen und benötigte Kompetenzen	63
A.2.4 Ergebnis	65
A.3 Betriebswirtschaftslehre/Soziologie: Gender Studies	67
A.3.1 Fragestellung	67
A.3.2 Vorgehen der Anwender*innen und benötigte Kompetenzen	67
A.3.3 Vorgehen der Expert*innen und benötigte Kompetenzen	70
A.3.4 Ergebnis	72
A.4 Verkehrswissenschaften: Mobilitätsplanung	75
A.4.1 Fragestellung	75
A.4.3 Vorgehen der Expert*innen und benötigte Kompetenzen	76
A.4.4 Ergebnis	78
A.5 Psychologie: Ethik in der Forschung	81
A.5.1 Fragestellung	81
A.5.2 Vorgehen der Anwender*innen und benötigte Kompetenzen	81
A.5.3 Vorgehen der Expert*innen und benötigte Kompetenzen	82
A.5.4 Ergebnis	84
Anhang B: Vorschlag für Kompetenzniveaus	88
Anhang C: Data Literacy Framework	90
C.1 Kompetenzfeld A: Datenkultur etablieren – Vom System zu messbaren Objekten	90
C.2 Kompetenzfeld B: Daten bereitstellen – Von messbaren Objekten zu Daten	92
C.3 Kompetenzfeld C: Daten auswerten – Von Daten zu Datenprodukten	98

4

HFD AP 47: Future Skills: Ein Framework für Data Literacy

Inhalt

C.4 Kompetenzfeld D: Datenprodukte interpretieren – Von Datenprodukten zu Daten	102
C.5 Kompetenzfeld E: Daten interpretieren – Von Daten zu messbaren Objekten	105
C.6 Kompetenzfeld F: Handeln ableiten – Von messbaren Objekten zum System	107
Literaturverzeichnis	109
Impressum	114

Abbildungs- und Tabellen- verzeichnis

Abbildung 1: Historische Einordnung des Begriffs "Data Literacy"	20
Abbildung 2: Pyramidenmodell des Prozesses der Daten-Wertschöpfung (angelehnt an Awad & Ghazari/Bellinger, Castro & Mills).....	22
Abbildung 3: Zyklusmodell des Prozesses der Daten-Wertschöpfung (angelehnt an Association of Independent Schools New South Wales u.a.)	22
Abbildung 4: Strukturmodell des Prozesses der Daten-Wertschöpfung (angelehnt an Münster) ...	23
Abbildung 5: Einordnung der Kompetenzbegriffe auf dem dreidimensionalen, integrierten Prozessmodell zur Daten-Wertschöpfung	25
Abbildung 6: Kompetenzfelder und Teilkompetenzen des Data Literacy Frameworks im Prozessmodell der Daten-Wertschöpfung	34
Abbildung 7: Einordnung der Instrumente in das Lernstufen-Modell.....	42
Abbildung 8: Das Data Literacy Framework und angrenzende Disziplinen und Rollen	50
Abbildung 9: Anteile der Patient*innen mit CI und zugehörige Konfidenzintervalle nach Scorewert (Jabbarli et al)	55
Abbildung 10: Vergleich der Patient*innenstichproben aus der Studie und der Datenbank	57
Abbildung 11: Visualisierung von Messzeitpunkten und Anomalien bei transformierten Daten.....	65
Abbildung 12: Visualisierung von Messzeitreihen und Anomalien bei Rohdaten	66
Abbildung 13: Boxplots der Verweildauer im Vorstand; ab 2007 im DAX-30 gelistete Unternehmen; neu berufene Vorstände	72
Abbildung 14: Kreuztabellen für verschiedene Merkmale von Vorstandsmitgliedern	73
Abbildung 15: Analyse der Überlebenszeit, nur nach Geschlecht.....	74
Abbildung 16: Analyse der Überlebenszeit, bereinigt um kritische Faktoren	74
Abbildung 17: Anfrageanalysen der Ziele (Mittwoch 7 bis 10 Uhr).....	78
Abbildung 18: Anfrageanalysen der Starts (Mittwoch 7 bis 10 Uhr)	78
Abbildung 19: Anfrageanalysen - Vergleich von zwei Tagen mit und ohne Sperrung der Hauptverkehrsader.....	79

Abbildung 20: Analyse der Netzauslastung (links) und Winkelanalyse zur Auslastungsanalyse des Zentrums (rechts).....	79
Tabelle 1: Kognitive und affektive Lernzieltaxonomie (Bloom, 1976; Krathwohl, Bloom & Masia, 1997).....	27
Tabelle 2: Kernkompetenzen von Carlson et al.	35
Tabelle 3: Ausschnitt aus dem Data Literacy Kompetenzrahmen (Kompetenzen C.1 und D.3)	39
Tabelle 4: Beispielaufgabe zu den Kompetenzen D.1 und E.1.....	51
Tabelle 5: Beispielaufgabe zusätzlich zur Kompetenz C.3	52
Tabelle 6: Übersicht der Fallstudien.....	54
Tabelle 7: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 1)	57
Tabelle 8: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 1).....	58
Tabelle 9: Rohwerte aus Jabbarli et al. (rekonstruiert).....	59
Tabelle 10: Fisher-Test (zweiseitig) auf Gleichheit der CI%-Anteile in den beiden Stichproben	60
Tabelle 11: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 2).....	62
Tabelle 12: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 2).....	65
Tabelle 13: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 3)	70
Tabelle 14: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 4)	71
Tabelle 15: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 4)	75
Tabelle 16: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 4)	77
Tabelle 17: Potenziale und Restriktionen der verschiedenen Datenquellen des Verkehrsverbundes	80
Tabelle 18: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 5)	82
Tabelle 19: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 4)	84
Tabelle 20: Ergebnisse Experiment 1	85
Tabelle 21: Ergebnisse Experiment 2	86
Tabelle 22: Kompetenzfeld A – Datenkultur etablieren	91
Tabelle 23: Kompetenzfeld B – Daten bereitstellen.....	97
Tabelle 24: Kompetenzfeld C – Daten auswerten:	101
Tabelle 25: Kompetenzfeld D – Datenprodukte interpretieren.....	104

7

HFD AP 47: Future Skills: Ein Framework für Data Literacy

Abbildungs- und Tabellen-verzeichnis

Tabelle 26: Kompetenzfeld E – Daten interpretieren.....	106
Tabelle 27: Kompetenzfeld F – Handeln ableiten.....	108

Das Hochschulforum Digitalisierung

Das Hochschulforum Digitalisierung (HFD) orchestriert den Diskurs zur Hochschulbildung im digitalen Zeitalter. Als zentraler Impulsgeber informiert, berät und vernetzt es Akteure aus Hochschulen, Politik, Wirtschaft und Gesellschaft.

Das HFD wurde 2014 gegründet. Es ist eine gemeinsame Initiative des Stifterverbandes für die Deutsche Wissenschaft mit dem CHE Centrum für Hochschulentwicklung und der Hochschulrektorenkonferenz (HRK). Gefördert wird es vom Bundesministerium für Bildung und Forschung.

Weitere Informationen zum HFD finden Sie unter:

<https://hochschulforumdigitalisierung.de>.

Eine Expert*innengruppe beim Hochschulforum Digitalisierung hat die Ausschreibung und dieses Arbeitspapier konzeptionell begleitet. In ihr haben mitgewirkt:

Arne Gerdes (Universität Göttingen),
Priv.-Doz. Dr. med. Sebastian Kuhn, MME (Universität Mainz),
Prof. Dr. Antje Michel (FH Potsdam),
Prof. Dr. Tobias Seidl (Hochschule der Medien Stuttgart).

Die Expert*innengruppe ist aus der Arbeitsgruppe Curriculum 4.0 hervorgegangen. Ziel der Arbeitsgruppe war es, übergreifende Elemente der Curriculumentwicklung vor dem Hintergrund des digitalen Wandels zu identifizieren sowie Good-Practice-Ansätze aufzuzeigen. Die Arbeitsgruppe hat eine Reihe von Diskussions- und Empfehlungspapieren erarbeitet, die Hochschulen im Überarbeitungsprozess ihrer Curricula zur Reflexion ihrer Studiengangskonzepte sowie zur konkreten Curriculumgestaltung nutzen können. Weitere Informationen zur Arbeitsgruppe finden Sie unter:

<https://hochschulforumdigitalisierung.de/de/themen/curriculum-40>



01

Kapitel 1: Zusammenfassung

1.1 Management Summary

Welches **Wissen**, welche **Fähigkeiten**, welche **Haltung** benötigt es in **Gesellschaft**, Arbeitswelt und Wissenschaft, in denen **Daten als wertvolle**, mitunter die wertvollste **Ressource** gelten und Entscheidungen zunehmend auf der Grundlage von Daten getroffen werden? Zweifellos werden Digitalisierung und Datafizierung das Leben und Arbeiten im 21. Jahrhundert nachhaltig verändern. Künstliche Intelligenz, vernetzte Produktion, kommunizierende Maschinen und selbstfahrende Autos werden von Daten gesteuert und produzieren selbst Daten am laufenden Band. Daten sind die Ausgangsbasis für **Wissens-** bzw. **Wertschöpfung** als Grundlage für bessere Entscheidungen.

Der Prozess der Wissensschöpfung umfasst mehrere Schritte: (A) Datenkultur etablieren – (B) Daten bereitstellen – (C) Daten auswerten – (D) Ergebnisse interpretieren – (E) Daten interpretieren – (F) Handeln ableiten. Um systematisch Wissen bzw. Wert aus Daten zu schöpfen, ist deshalb zukünftig in allen Sektoren und Disziplinen die **Fähigkeit, planvoll mit Daten umzugehen** und sie im jeweiligen Kontext bewusst einsetzen und hinterfragen zu können, von entscheidender Bedeutung. Dies wird als **Data Literacy** bezeichnet und umfasst die Fähigkeiten, Daten auf kritische Art und Weise zu sammeln, zu managen, zu bewerten und anzuwenden. Data Literacy ist weit mehr als ein breites und tiefes Detailwissen über sich laufend verändernde Methoden und Technologien. Vielmehr spielt die Dimension der **Datenethik, der Motivation und Werthaltung** eine zentrale Rolle, um zukünftig mit Daten erfolgreich und souverän umgehen zu können.

Data Literacy ist eine **Schlüsselkompetenz des 21. Jahrhunderts**, die in der modernen Gesellschaft und Arbeitswelt unerlässlich sein wird. Data Literacy muss deshalb von Beginn an und fächerübergreifend an den Hochschulen vermittelt werden. Hierfür bedarf es eines **Kompetenzrahmens**, d.h. eines Modells zur strukturierten Beschreibung von effektivem Verhalten in einem gegebenen Aufgabenkontext. Er umfasst Kompetenzen, deren Definitionen und daraus abgeleitete Verhaltensindikatoren. Ein derartiger Kompetenzrahmen soll alle Stufen des Wissens- bzw. Wertschöpfungsprozesses aus Daten abbilden; er soll alle Kompetenzdimensionen erfassen: (a) Wissen, (b) Fertigkeiten, (c) Fähigkeiten, (d) Motivation und (Wert-)Haltung; er soll es erlauben, die erfassten Kompetenzen in konkrete und testbare Lern- oder Kompetenzziele zu überführen; und er soll die Interdisziplinarität der Aufgabe reflektieren, also widerspiegeln, dass neben Datenexpert*innen auch Fachleute für Datenschutz und Datenethik benötigt werden.

Außerdem ist zu erforschen, wie Data Literacy gemessen und getestet werden kann. Geeignete **Mess- und Testinstrumente** erfassen kognitive und affektive Lernbereiche; sie umfassen möglichst viele Lernstufen: (a) Reaktion, (b) Lernerfolg, (c) Verhalten, (d) Ergebnis; sie sind transparent bezüglich der Möglichkeiten und Grenzen einer Schlussfolgerung von beobachtbarem Verhalten auf dahinter liegender Kompetenz; sie genügen den Testgütekriterien der Validität, Reliabilität und Objektivität; und schließlich sind sie mit vertretbarem Aufwand (Geld, Zeit, benötigte Fähigkeiten der Prüfer*innen) durchzuführen.

Die vorliegende Studie verfolgt somit **zwei Ziele**. Erstens soll ein Kompetenzrahmen für Digitalkompetenzen am Beispiel von Data Literacy entwickelt und **umsetzbares Wissen** für

Hochschulen verfügbar gemacht werden. Zweitens soll die Messung von Wirkung und Qualität von Lehre und Studium im digitalen Zeitalter wie auch die **Testentwicklung für Digitalkompetenzen** am Beispiel von Data Literacy vorbereitet werden. Die Studie richtet sich **an Verantwortliche für die Curriculumentwicklung** in der Hochschulpolitik und den Hochschulen selbst, aber auch an **Lehrende**, die nach konkreten Ansätzen zur Vermittlung und Evaluation von Data Literacy suchen. Hierfür stellt das Arbeitspapier einen ausdifferenzierten Kompetenzrahmen zur Verfügung, der zur Ableitung von Lernzielen in zahlreichen Fachgebieten und Studiengängen dienen kann. Mögliche Mess- und Testverfahren für Data Literacy werden näher beleuchtet. Beispielhaft ist anhand von Fallstudien aufgezeigt, wie der Kompetenzrahmen in realen Problemsituationen dazu beitragen kann, Daten nutzbar zu machen.

Nun gilt es, die erarbeiteten Ergebnisse in **Vorschläge für Curricula** umzusetzen. Dafür müssen Pilothochschulen und Pilotstudiengänge ausgewählt werden, in denen spezifische Lernziele für die jeweiligen Disziplinen aus dem Kompetenzrahmen abgeleitet werden. Zu diskutieren ist weiter der Aspekt des **lebenslangen Lernens** von Schlüsselkompetenzen: Wie kann bzw. sollte Data Literacy bereits in der Schule sowie später in der Arbeitswelt und der Erwachsenenbildung vermittelt werden? In jedem Fall braucht es didaktische Ansätze, die der **Interdisziplinarität** der Aufgabe gerecht werden, denn komplexe Datenprojekte werden bereits heute im Team bearbeitet, sie erfordern ein multiprofessionelles Arbeiten, das die Fähigkeit zum Projektmanagement und die Kenntnis organisatorischer, rechtlicher und ethischer Rahmenbedingungen miteinschließt. Nicht zuletzt bedarf die Frage, wie die Lehrenden für diese Herausforderung qualifiziert werden können, einer Antwort.

1.2 Aufbau des Arbeitspapiers

Das vorliegende Arbeitspapier fasst das Ergebnis der Studie in einem Bericht zusammen. Ein Überblick über Ausgangslage und Zielsetzung beleuchtet im Kapitel **Hintergrund und Zielsetzungen** zunächst die Herausforderungen durch Digitalisierung und Datafizierung und beschreibt dann die Ziele der Studie. Im Anschluss wird der Begriff „Data Literacy“ präzisiert, wobei zunächst abgeleitet wird, welche Implikationen die Betrachtungsweise von Data Literacy als 21st Century Skill mit sich bringt. Es folgen eine Diskussion möglicher Zwecke von Data Literacy und eine Abgrenzung des Begriffs. Daraus leiten sich Anforderungen an einen Kompetenzrahmen und an mögliche Mess- und Testinstrumente ab.

Es folgt im nächsten Kapitel die **Herleitung des Kompetenzrahmens**. Nach einer Darstellung der historischen Entwicklung der Begriffsdefinition wird die kompetenzdefinierende Aufgabe der Wertschöpfung aus Daten näher erläutert. Vor diesem Hintergrund werden Data Literacy und andere Kompetenzen eingeordnet und voneinander abgegrenzt. Haltung als Kompetenzdimension wird im folgenden Unterkapitel betrachtet; es folgen im Ausblick Impulse zur Ableitung überprüfbarer Lernziele und zur didaktischen Umsetzung in anderen Disziplinen. Schließlich wird der Kompetenzrahmen in der Literatur verortet.

Das nächste Kapitel beinhaltet die detaillierte **Darstellung des Kompetenzrahmens** für Data Literacy als Kernergebnis der Studie. Intention und **Einsatzmöglichkeiten** sowie die Gliederungsebenen werden vorgestellt; danach wird aufgezeigt, wie die Kompetenzdefinition in einen Kompetenzrahmen mündet. Insbesondere werden **Kompetenzfelder** und Kompetenzen sowie die **(Wert-)Haltung** als Kompetenzdimension vorgestellt. Zwei korrespondierende Kompetenzen werden im Detail vorgestellt.

Anschließend beleuchtet der Forschungsbericht im Kapitel zur **Messung und Testung von Data Literacy** mögliche Instrumentarien, die zur praktischen Entwicklung von **Mess- und Testinstrumenten** für Data Literacy genutzt werden können, und schlägt einen Rahmen zu deren Einordnung vor. Aus der Literaturanalyse heraus ergeben sich verschiedene Varianten von objektiven und interpretativen Testverfahren als Ankerpunkte. Schließlich werden Beispiele multipler Methoden diskutiert.

Das Abschlusskapitel **Reflexion und Ausblick** reflektiert die Arbeit und gibt einen kurzen Ausblick auf **weitere Forschungsaufgaben**. Zunächst wird die Diskussion mit Fachexpert*innen, Hochschulprofessor*innen und Führungskräften zusammengefasst. Sie thematisiert die veränderte Bedeutung von Data Literacy, die Wahrnehmung von Haltung als Kompetenzdimension und die Frage, inwiefern Data Literacy heute schon (standardisiert) gemessen wird. Der Ausblick auf **Lernziele und Qualifikationsniveaus** sowie die Testentwicklung beschließt den Forschungsbericht.

1.3 Abgrenzung und Bezug zum zweiten Arbeitspapier der Studie

Die Studie „Entwicklung eines Kompetenzrahmens und vorbereitende Studie zur Kompetenzmessung von 21st Century Skills am Beispiel von Data Literacy“ umfasst insgesamt zwei Arbeitspapiere. Neben dem vorliegenden Forschungsbericht ist dies ein **Systematic Review** [Schüller & Busch, 2019a].

Das vorliegende Dokument fasst die Ergebnisse der Studie insgesamt zusammen und sammelt Instrumente, welche die Grundlage für Testentwicklung in einem Folgeprojekt bilden können. Es liefert zudem eine ausführliche Dokumentation des entwickelten Kompetenzrahmens einschließlich der Überlegungen zu seiner Herleitung.

Das Systematic Review liefert einen ausführlichen Vorgehens- und Ergebnisbericht über die Recherche und Einordnung der Vorarbeiten. Er dient der weiteren Forschung sowie der Auswahl potenziell geeigneter, existierender Test- und Messinstrumente für Data Literacy für praktische Projekte.



02

Kapitel 2: Hintergrund und Zielsetzung

2.1 Herausforderungen durch Digitalisierung und Datafizierung

Vor fast genau einem Jahrzehnt prognostizierte Hal Varian, der Chefökonom von Google, in einem Artikel der New York Times: „Ich bleibe dabei zu sagen, dass die sexy Jobs in den nächsten zehn Jahren Statistiker sein werden“ (Lohr, 2009). Wenige Zeilen später ergänzt Erik Brynjolfsson, Ökonom und Direktor des Massachusetts Institute of Technology Center for Digital Business: „Wir geraten rapide in eine Welt, in der alles überwacht und gemessen werden kann, aber das große Problem wird die Fähigkeit der Menschen sein, diese Daten zu nutzen, zu analysieren und ihnen Sinn zu verleihen.“

Doch wie kommt man von Daten zum sinnvollen Handeln? Daten sind nur der Rohstoff. Daten stellen Abstraktionen der realen Welt dar, durch Bereinigen und Verknüpfen entstehen aus Daten Informationen. Organisierte, d.h. analysierte Daten schaffen Wissen, und angewandtes, d.h. sinnvoll interpretiertes und genutztes Wissen, konstituiert Weisheit oder – wie es der französische Philosoph Michel Foucault nennt – Macht (vgl. Foucault & Gordon, 1980). Wie genau jedoch dieser Prozess abläuft, ob es sich um eine lineare Abfolge handelt oder eine zyklische, wo der Startpunkt ist und ob zwingend stets alle Prozessschritte durchlaufen werden müssen, bleibt zunächst offen.

Fest steht: Daten sind heute ubiquitär, Digitalisierung führt zwangsläufig zu einer Datafizierung, weil die analoge Welt in eine digitale abgebildet wird. In nahezu allen Disziplinen werden heute Daten in großen Mengen erhoben oder entstehen als Nebenprodukt, sie dienen der laufenden Überwachung, Planung, Steuerung und Bewertung. Beispiele sind etwa Sensordaten in der Produktion, digitale Versichertendaten, Daten von Fitness-Trackern, Verkehrsflussdaten, Kundendaten in CRM-Systemen und viele andere. Diese Daten werden zunehmend nicht mehr nur zu ihrem ursprünglichen Erhebungszweck genutzt, der häufig auf die Optimierung bestehender Prozesse ausgerichtet war, sondern sollen neue Analysemöglichkeiten eröffnen, die beispielsweise auf die Entwicklung innovativer Geschäftsmodelle abzielen.

Darüber hinaus durchdringen Daten und deren Derivate wie Statistiken oder Grafiken infolge der Entwicklung eines (mehr oder weniger professionell umgesetzten) Datenjournalismus sämtliche traditionellen und neuen Medien. Sie sind dort verbalisiert, kontextualisiert und müssen von Rezipient*innen extrahiert und neu eingeordnet werden, wenn die Interpretationen der Produzent*innen nicht unkritisch übernommen werden sollen. Studien können nicht mehr nur von Hochschulen, etablierten Forschungsinstituten und Beratungsfirmen erstellt werden. Vielmehr ermöglicht es die Demokratisierung des Datenzugangs (etwa durch Open Data) und der Datenverarbeitung (etwa durch intuitiv nutzbare Werkzeuge wie das Google Produkt „Data Play“) auch Laien, (Trug-)Schlüsse aus Daten zu ziehen und diese auf Portalen wie medium.com und sozialen Netzen wie Facebook einem breiten Publikum zu präsentieren und einen Beitrag zur Wissens- oder auch nur zur Meinungsbildung zu leisten.

2.2 Ziele der vorliegenden Studie

Die Studie „Future Skills: Ein Framework für Data Literacy“ verfolgt zwei Ziele: Erstens soll ein Kompetenzrahmen für Digitalkompetenzen am Beispiel von Data Literacy entwickelt und umsetzbares Wissen für Hochschulen verfügbar gemacht werden. Zweitens soll die Messung von Wirkung und Qualität von Lehre und Studium im digitalen Zeitalter wie auch die Testentwicklung für Digitalkompetenzen am Beispiel von Data Literacy vorbereitet werden.

Das Arbeitspapier des Hochschulforums Digitalisierung zu „Data Literacy Education“ (HFD-Arbeitspapier 37, 2018) formuliert angelehnt an Ridsdale eine Kompetenzmatrix mit fünf Kompetenzbereichen, Einzelkompetenzen und einer Bewertung nach Schwierigkeitsgrad (Heidrich, Bauer & Krupka, 2018). Der Kompetenzrahmen zu Digitalkompetenzen des EU Science Hub (DigComp 2.0) verortet hingegen Daten- und Informationskompetenz als eine von vier Teilkompetenzen der Digitalkompetenz („The Digital Competence Framework 2.0 - EU Science Hub European Commission“, 2018). Dabei werden die Begriffe Daten- und Informationskompetenz nicht voneinander abgegrenzt, zudem fehlen Kompetenzen, die in der vorbereitenden Studie als Kernkompetenzen definiert werden.

Im Gegensatz dazu entwickelte das Projekt ProCivicStat ein weit umfangreicheres konzeptuelles Modell (Nicholson, Gal & Ridgway, 2018). Es setzt Data Literacy beziehungsweise Statistical Literacy in Bezug zu Kontextwissen und differenziert stärker zwischen Datenformen, die im wissenschaftlichen Umfeld auftreten, sowie Datenformen, mit denen die Bürger*innen in Berührung kommen. Dies schafft den Bezug zur Frage, welchen Ausbildungszweck (Kompetenzvermittlung für mündige Bildungsbürger*innen oder für Fachdisziplinen) der Rahmen abbilden soll.

Data-Literacy-Kompetenzen sollen es ermöglichen, reale Probleme zu adressieren und zu lösen. Insbesondere Problemstellungen mit gesellschaftlichem Bezug erfordern – anders als Probleme im technischen Umfeld, in denen Daten z. B. zur Qualitätssicherung von Produktionsprozessen genutzt werden – besondere Kompetenzen (Datenethik, Messbarkeit von Phänomenen, Einordnung der Ergebnisse in Kontextwissen, Ableitung von Handlungsempfehlungen). Da die Prüfungen, denen sich Studierende unterziehen müssen, als stärkster Indikator über das zu Lernende aufgefasst werden, müssen entsprechende Tests auch für die „weichen“ Kompetenzen entwickelt werden.

2.3 Präzisierung des Begriffs „Data Literacy“

Um den Prozess der Transformation von Daten in „Macht“, also Handlungswissen und Handlungsfähigkeit kontrolliert und verantwortungsvoll durchführen zu können, bedarf es Data Literacy. Diese Kompetenz befähigt Menschen, reale Probleme durch die Nutzung, Analyse und Interpretation von Daten, die zugrunde liegenden Phänomene zu messen sowie zu adressieren. Sie ist unerlässlich für das Verständnis komplexer, gesellschaftlich relevanter Phänomene wie globale Wirtschafts- und Finanzverflechtungen, Migration oder Klimawandel. Im Zeitalter der Digitalisierung liegen uns nicht nur mehr Daten vor, um diese Phänomene zu messen, sondern unter Umständen auch mehr ungeeignete Daten, die es sorgfältig zu evaluieren gilt. Zudem ermöglicht es die Digitalisierung weitaus mehr Menschen als früher, über diese Phänomene öffentlich zu diskutieren und Einfluss zu nehmen.

2.3.1 Data Literacy als Schlüsselkompetenz der 21. Jahrhunderts

Kompetenzen sind nach der Definition von Weinert „die bei Individuen verfügbaren oder durch sie erlernbaren kognitiven Fähigkeiten und Fertigkeiten, um bestimmte Probleme zu lösen, sowie die damit verbundenen motivationalen, volitionalen und sozialen Bereitschaften und Fähigkeiten, um die Problemlösungen in variablen Situationen erfolgreich und verantwortungsvoll nutzen zu können“ (Weinert, 2014). Diese Referenzdefinition umfasst also neben dem Wissen (Knowledge) und der Fähigkeit, dieses Wissen anzuwenden (Skills) auch die Bereitschaft, dies zu tun (Values).

Data Literacy wird deshalb mit gutem Grund im HFD-Arbeitspapier 37/18 als „zentrale Kompetenz für die Digitalisierung und die globale Wissensgesellschaft in allen Sektoren und Disziplinen“ (Heidrich et al., 2018) bezeichnet. Es gilt, diese Kompetenz systematisch in die Bildung zu integrieren, insbesondere in die Curricula von Hochschulen.

2.3.2 Mögliche Zwecke von Data Literacy

Die im HFD-Arbeitspapier 37/18 verwendete, an Ridsdale angelehnte Definition präzisiert Data Literacy als „die Fähigkeit, Daten auf kritische Art und Weise zu sammeln, zu managen, zu bewerten und anzuwenden“ (Ridsdale et al., 2015). Zugleich hält die Studie im Fazit fest, dass Data Literacy verschiedenen Zwecken dienen kann. Einerseits werden Datenkompetenzen benötigt, um Daten professionell im Rahmen eines spezifischen Fachgebiets zu nutzen. Dies umfasst nicht nur die Forschung an Hochschulen, die zunehmend auf neue Datenquellen („Big Data“) und dafür entwickelte Werkzeuge aus der Disziplin der „Data Science“ zugreifen kann, sondern auch Forschung und Entwicklung in Unternehmen. Daten dienen dort als Rohstoff für Innovationen, sie gelten als „Öl des 21. Jahrhunderts“.

Andererseits lässt sich Data Literacy als die Fähigkeit auffassen, die ein mündiger Bürger in der Digitalisierung benötigt, um sich in einem Überangebot von Daten und Informationen zurechtzufinden und fundierte Entscheidungen zu treffen – im Alltag wie auf verschiedenen politischen Ebenen. Diese Entscheidungskompetenz setzt Unterscheidungsfähigkeit voraus, um Daten und Informationen von Interpretationen und Meinungen zu differenzieren. „Wir ertrinken in Informationen und dürsten nach Wissen“, formuliert es der Zukunftsforscher John Naisbitt, und Herbert G. Welles wird folgende Prognose zugeschrieben: „Wenn wir mündige Bürger in einer modernen technologischen Gesellschaft möchten, dann müssen wir ihnen drei Dinge beibringen: Lesen, Schreiben und statistisches Denken, das heißt den vernünftigen Umgang mit Risiken und Unsicherheiten.“

2.3.3 Abgrenzung des Begriffs

Nicht nur Data Literacy, sondern auch Information Literacy, Statistical Literacy bzw. Statistisches Denken und neuerdings auch Data Science Literacy sind Begriffe, die immer wieder als essentielle Kompetenzen in Bezug auf die Digitalisierung genannt werden. Offensichtlich ist die Abgrenzung der Begriffe keinesfalls abschließend geklärt. Ein kurzer Blick auf die historische Entwicklung der Begriffe mag helfen. Dabei steht jedoch die Gefahr im Raum, dass Definitionen bewusst ausgedehnt werden, weil „Data Science“ zum Modebegriff wird. Dahinter steckt womöglich auch in Teilen ein ökonomisches Interesse: Die am Markt gezahlten Gehälter in neuen Berufen wie „Data Engineer“ oder „Data Scientist“ sind immerhin erheblich höher als diejenigen von Statistiker*innen oder IT-Expert*innen.

Selbst die Frage, um was es sich bei den Konzepten Daten, Information und Wissen handelt, ist nicht mehr so klar zu beantworten, spätestens seit „Big Data“ unter den Datenbegriff auch Bilder

oder ganze Texte fasst. Nicht zuletzt trägt die rapide Entwicklung von Technologien und Werkzeugen zur automatisierten Erhebung, Speicherung und Analyse solcher semi- und unstrukturierten Daten dazu bei, dass es sich um fluide Konzepte handelt: Je nach Forschungsfrage kann das, was im ersten Kontext bereits Information ist, also mit Sinn erfüllte Daten, im zweiten Kontext wiederum Datum sein.

2.4 Anforderungen an Kompetenzrahmen und Testinstrumente

Noch deutlicher wird dieser Aspekt durch Rainer Kuhlens Definition von Information als „Wissen in Aktion“ (Kuhlen, 2013). Für die Gestaltung eines Kompetenzrahmens und bei der Ableitung von Lernzielen für die Vermittlung von Data Literacy – die im Anschluss an die vorliegende Studie als nächster Schritt empfohlen wird – sollten deshalb erstens (mindestens) Information Literacy und Data Literacy konvergent betrachtet werden. Alle Stufen des Prozesses der Wertschöpfung aus Daten beziehungsweise der Entscheidungsfindung mit Daten müssen abgebildet sein.

Zweitens muss die Mehrdimensionalität des Kompetenzbegriffs von einem Kompetenzrahmen erfasst werden. Seidl et al. fordern, dass bei der Entwicklung von 21st Century Skills an Hochschulen „ein Rahmen geschaffen werden [muss], in dem (a) dieses komplexe Wissen, (b) Fertigkeiten, (c) Fähigkeiten sowie (d) motivationale Orientierung und (Wert-)Haltung erworben und entwickelt werden können“ (Seidl et al., 2018). Motivation und (Wert-)Haltung müsse angesichts der sich verändernden Kompetenzprofile im Zuge des digitalen Wandels einen zentralen Stellenwert erhalten.

Drittens soll ein Kompetenzrahmen die Grundlage dafür schaffen, dass die dort erfassten Kompetenzen in konkrete und testbare Lern- oder Kompetenzziele überführt werden können. Dies gilt „nicht nur im Bereich des Wissens und der Fertigkeiten/Fähigkeiten, sondern gerade auch im Bereich der motivationalen Orientierung und der (Wert-)Haltung“ (Seidl et al., 2018). Dazu müssen die Kompetenzen ausreichend operationalisiert und ausformuliert sein, idealerweise mit einer ersten Einteilung in Kompetenzstufen oder Leistungsniveaus. Dies ist Voraussetzung dafür, dass Mess- und Testinstrumente für Data Literacy ausgewählt und entwickelt werden können.

Viertens soll der Kompetenzrahmen der Tatsache Rechnung tragen, dass die mit Hilfe von Daten zu lösenden Aufgaben zunehmend komplex und interdisziplinär sind. Die Übergabepunkte zwischen Fach- und Methodendisziplinen verschwimmen und rücken zudem in den Fokus rechtlicher und ethischer Überlegungen; es ist nicht (mehr) so einfach, Daten zu erheben, zu verarbeiten und zu nutzen, gerade wenn Dritte an der Auswertung beteiligt werden sollen. Mit der Zunahme der Resource Daten und ihrer immer intensiveren Nutzung entstehen neue Berufe wie Data Engineers, Data Scientists, Data Designer*innen oder Datenjournalist*innen. Es gilt ein Bild zu entwerfen, wie diese Professionen zukünftig ineinandergreifen, um zu verstehen, welche Kompetenzen übergreifend und welche fachspezifisch vermittelt werden sollten und wen es dafür braucht.

2.4.1 Anforderungen an Mess- und Testinstrumente für Data Literacy

Zur Identifikation und (Weiter-)Entwicklung von geeigneten Mess- und Testinstrumenten ist es empfehlenswert, eine Reihe von Überlegungen hinsichtlich der Charakteristika des zu Erlernenden anzustellen. Affektive Lernbereiche, zu denen die Motivation und die (Wert-)Haltung zählen, resultieren in anderen Lernzielen als die kognitiven Lernbereiche des komplexen Wissens und der Fähigkeiten und Fertigkeiten. Dabei bestehen mutmaßlich Wechselwirkungen zwischen dem Erreichen der affektiven und der kognitiven Lernziele: Je stärker der Wert oder Nutzen des zu Erlernenden verinnerlicht wird, desto mehr Motivation besteht, sich Wissen anzueignen, und der erreichte Wis-

sensstand beeinflusst die Fähigkeit, das Erlernete anzuwenden. Umgekehrt steigt die Motivation mit der Erfahrung, dass das Erlernete erfolgreich angewendet werden kann, und durch die erfolgreiche Anwendung steigt zugleich das Verständnis von komplexem Wissen.

Kirkpatrick schlägt ein Stufenmodell zur Evaluation von Lernprozessen vor, das die vier aufeinander aufbauenden Stufen Reaktion („Did they like it?“), Lernerfolg („Did they get it?“), Verhalten („Can they do it?“) und Ergebnis („Does it matter?“) umfasst (Kirkpatrick, 1959/60). Die beiden letzteren Stufen beziehen sich auf das Verhalten und dessen Wirkung außerhalb des Lernumfeldes, also in realen Situationen. Dabei wird rasch klar, dass im Kontext (hoch-)schulischer Prüfungen die Stufe 3 nur eingeschränkt und die Stufe 4 praktisch nicht evaluierbar sind, weil sie dadurch geprägt sind, dass effizientes und effektives Verhalten ohne (unmittelbaren) extrinsischen Motivator gezeigt wird. Dass ein*e Studierende*r sich in einer komplexen Fallstudie oder Abschlussarbeit bemüht, auch zeitaufwändige Arbeitsschritte wie etwa die Datenaufbereitung zu erledigen, mag zwar darin begründet sein, dass er oder sie die Bedeutung einer guten Datenqualität verinnerlicht hat, aber womöglich motiviert ihn oder sie lediglich die Aussicht auf eine gute Note. Von der sichtbaren Leistung lässt sich hier gerade nicht auf die unsichtbare Kompetenz beziehungsweise Kompetenzdimension schließen. Dies gilt umso mehr, als manche Typen von Tests mehr dazu verleiten, (nur) auf den Test hinzulernen.

In Anlehnung an die einschlägige Literatur zur Gestaltung von Mess- und Testinstrumenten sollte daher eine Abwägung erfolgen zwischen den klassischen Testgütekriterien Validität, Reliabilität und Objektivität und den Kosten der Erstellung, Durchführung und Bewertung. Dabei werden neben monetären Größen auch der jeweilige Zeitaufwand und die benötigten Fähigkeiten der Prüfenden in die Auswahlentscheidung einfließen.



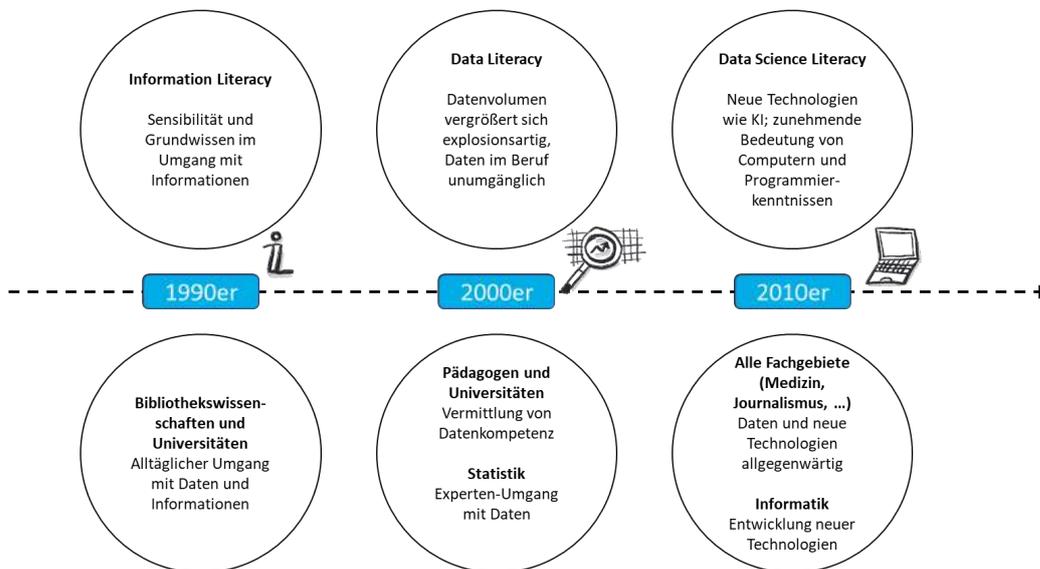
03

Kapitel 3: Herleitung eines Kompetenzrahmens

3.1 Vom Aufgabenverständnis zur Kompetenzdefinition

In den 1990er Jahren wurde zunächst der Begriff Information Literacy geprägt. So beschrieb Wallman 1993 Information Literacy als die Fähigkeit, statistische Aspekte des alltäglichen Lebens zu verstehen und kritisch betrachten zu können (Wallman, 1993). Watson entwickelte diesen Begriff 1997 weiter, indem sie den Begriff in drei aufsteigende Kompetenzlevel einteilte (Watson, 1997). Auf dem ersten, untersten Level ist ein grundlegendes Verständnis von statistischen Begriffen vorhanden, auf dem zweiten bereits ein Verständnis der statistischen Fachsprache und von deren Konzepten. Der letzte Level erfordert die Fähigkeit, komplexere Konzepte anzuwenden, um Aussagen kritisch zu hinterfragen. In dieser Zeit wurde der Begriff noch hauptsächlich in dem Gebiet der Bibliothekswissenschaften diskutiert, einem Bereich, der sich hauptsächlich mit dem Verarbeiten von Informationen und Statistiken beschäftigt.

GEPRÄGTE BEGRIFFE



PRÄGENDE BEREICHE

Abbildung 1: Historische Einordnung des Begriffs "Data Literacy"

In den 2000er Jahren entwickelte sich der Begriff der Data Literacy. Die Abgrenzung dieses Begriffs von demjenigen der Statistical Literacy variiert je nach Autor*in. Schield etwa beschreibt 2004 Data Literacy als einen Teil der Statistical Literacy, der sich direkt auf den Umgang mit Daten bezieht, während sich Statistical Literacy allgemeiner mit dem kritischen Hinterfragen von deskriptiven Statistiken befasst (Schield, 2004). Zunehmend wurde die Begriffsdefinition von Pädagog*innen und Hochschulen thematisiert, die sich mit der Frage auseinandersetzten, wie man Data Literacy unterrichten könne. In den letzten Jahren wurden neue Begriffe geprägt, die vermehrt auch den Umgang mit Computern und neuen Techniken wie etwa Künstliche Intelligenz integrieren. So de-

finieren Dichev und Dicheva 2017 Data Science Literacy als Kombination von Computational Literacy, Statistical Literacy, Machine Learning Literacy, Visualisation Literacy und Ethical Literacy (Dichev & Dicheva, 2017). Die jüngsten Entwicklungen legen einen Schwerpunkt auf Kompetenzen in IT Bereichen, andererseits rücken ethische Kompetenzen in den Fokus, da ein ethischer Umgang mit Daten und Informationen insbesondere aufgrund der aktuellen Gesetzgebung (DSGVO, e-Privacy-Verordnung) und aufgrund publik gemachter Verstöße (z. B. die problematische Datenweitergabe von Facebook in Zusammenhang mit dem amerikanischen Präsidentschaftswahlkampf) die öffentliche Diskussion beherrscht.

3.1.1 Wertschöpfung aus Daten als kompetenzdefinierende Aufgabe

„Daten auf kritische Art und Weise zu sammeln, zu managen, zu bewerten und anzuwenden“, definiert mit Ridsdales Worten einen Prozess, für dessen Beherrschung Data Literacy vonnöten ist (Ridsdale et al., 2015). Es liegt deshalb nahe, die hierfür benötigten Kompetenzen anhand der einzelnen Prozessschritte dieser „Wissenschöpfung“ anzuordnen. In der Forschung zur Information Literacy wird hierfür häufig ein Stufenmodell gewählt wie das DIKW-Modell (Data, Information, Knowledge, Wisdom). Es stellt schematisch dar, wie durch einen zunehmenden Grad an Organisation Rohdaten im menschlichen Gehirn zu Informationen, Wissen und Weisheit verarbeitet werden. Nach der Bereinigung und Verknüpfung einzelner Datenelemente zu bedeutsamer Information suchen wir nach Mustern, wenden Analyseprinzipien an und strukturieren die Informationen beispielsweise durch Klassifikation oder Kategorisierung. Vorgelagert ist noch die Messung als Abbildungsprozess von Objekten der realen Welt in Daten.

Mit der begrifflichen Entwicklung von Data (Science) Literacy und Statistical Literacy verlagert sich die Perspektive hin zu einer zyklischen Darstellung des Prozesses („Data informed decision making cycle“, o. J.). Diese Darstellungsweise betont die Integration der Datenanalyse in eine konkrete Forschungsfrage oder Entscheidungssituation, während die etablierte Statistik-Ausbildung an den Hochschulen den Erwerb von Fachwissen und das Erlernen von Methoden in den Vordergrund stellt. Gleichwohl steht der abgebildete Zyklus in der Tradition der etablierten empirischen Forschung, die im Sinne eines hypothesengetriebenen bzw. konfirmatorischen Vorgehens von einer oder mehrerer Forschungsfragen ausgeht („Science starts with a question“). Daten werden entsprechend dem Analysezweck beschafft, aufbereitet, ausgewertet und interpretiert, um diese Fragen zu beantworten.

Durch die Digitalisierung entstehen Daten jedoch „zweckfrei“ in großer Menge und Heterogenität und eröffnen selbst neue Fragen („Data Science starts with the data“). Datengetriebenes bzw. exploratives Vorgehen verbreitet sich in der Praxis zunehmend, so dass neue Kompetenzen hinsichtlich des Umgangs mit neuen Formen von Daten – Text, Ton, Bild – jenseits der bekannten Skalenniveau-Einteilungen und Speicherungsformen benötigt werden. Google beschreibt sein Produkt „Data Studio“ mit den Worten: „Unlock the power of your data with interactive dashboards and beautiful reports that inspire smarter business decisions. It's easy and free“ (Data Studio Product Overview, o. J.). Dies betont die explorative Herangehensweise, „die Daten für sich sprechen zu lassen.“ Dabei ist das Risiko von Fehlschlüssen hoch, wenn ein grundlegendes Verständnis für statistische Fehler wie das Verwechseln von Korrelation und Kausalität fehlt oder wenn unerkannte Mängel in der Qualität der Daten (z.B. ein Bias) vorliegen. Schließlich ist Ethical Literacy erforderlich, wenn Daten frei kombiniert und für andere Zwecke als ihren ursprünglichen Erhebungszweck analysiert werden.

Münster schlägt in einer Visualisierung ein ebenfalls zyklisches Prozessmodell vor, das Visualisation Literacy als produktive Kodierungs-Kompetenz und Visual Literacy als korrespondierende, rezepptive Dekodierungs-Kompetenz schematisch abbildet (Münster, 2019). In den Blick nimmt sie dabei insbesondere den Kontext, aus dem Daten abgeleitet werden beziehungsweise auf dem aus Daten geschlossen werden soll. Das Modell steht in offensichtlichem Bezug zum Modell des statistischen Lernens nach Wild (Wild, 2012).

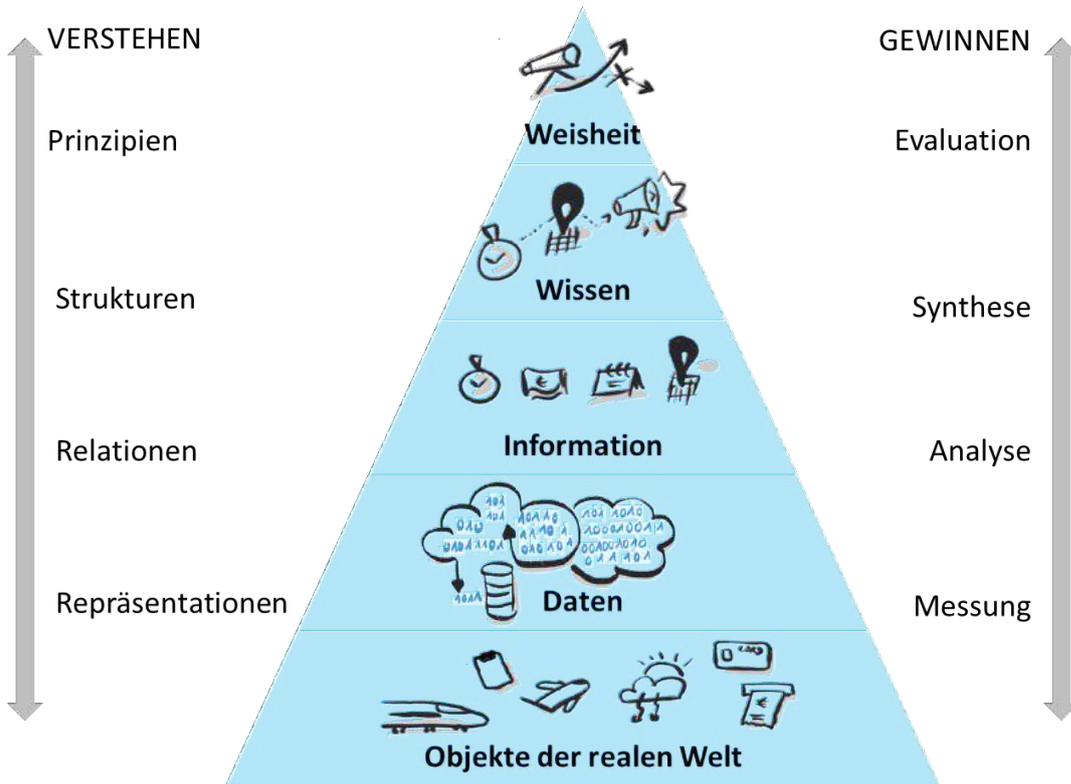


Abbildung 2: Pyramidenmodell des Prozesses der Daten-Wertschöpfung (angelehnt an Awad & Ghazari/Bellinger, Castro & Mills)

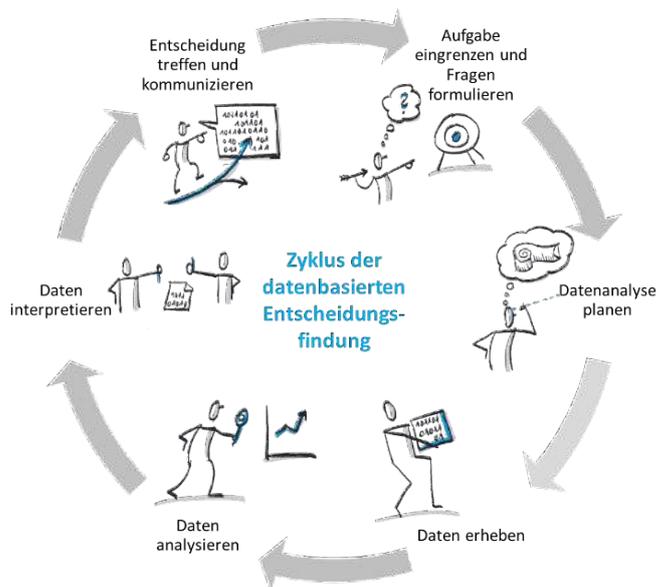


Abbildung 3: Zyklusmodell des Prozesses der Daten-Wertschöpfung (angelehnt an Association of Independent Schools New South Wales u.a.)

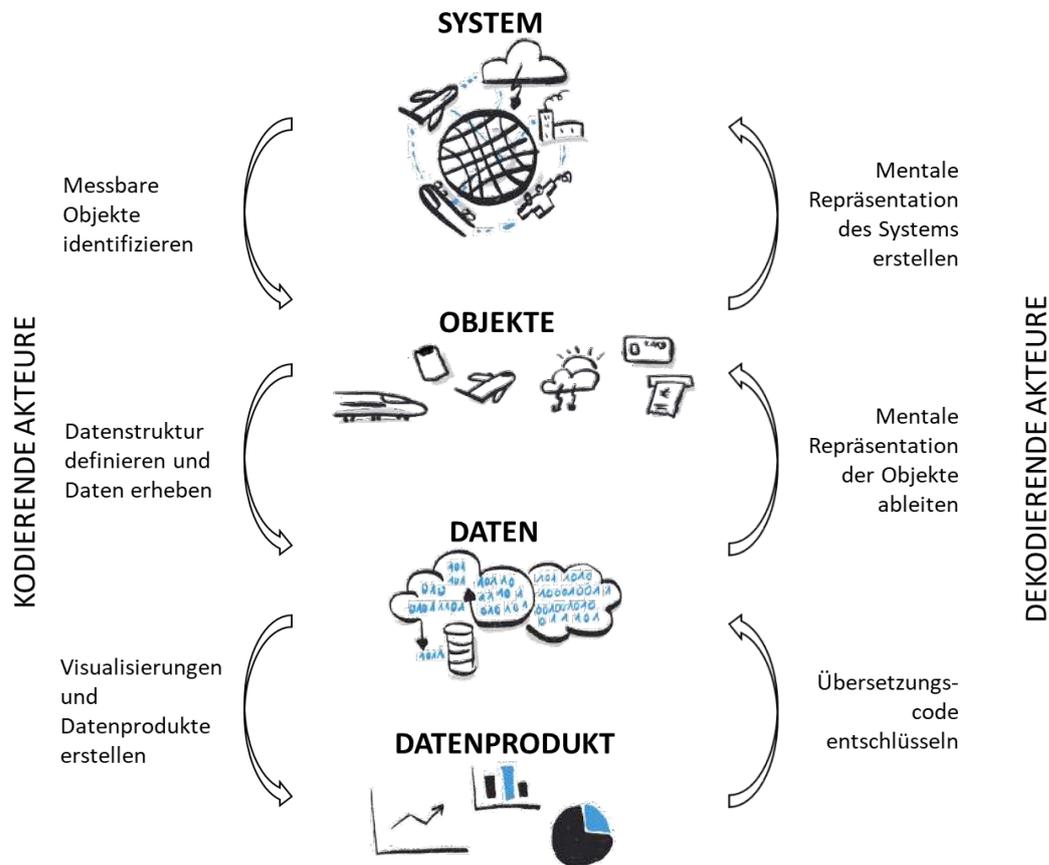


Abbildung 4: Strukturmodell des Prozesses der Daten-Wertschöpfung (angelehnt an Münster)

3.1.2 Einordnung und Abgrenzung der Kompetenzbegriffe

Jede Abgrenzung des Begriffs „Data Literacy“ von Begrifflichkeiten wie „Information Literacy“, „Digital Literacy“ oder auch „Statistical Literacy“ ist in gewissem Maße willkürlich und die Übergänge zwischen den dahinterliegenden Konzepten sind fließend. Selbst wenn man den Versuch unternimmt, Teilkompetenzen wie etwa die Visualisation Literacy oder die Computational Literacy unterschiedlichen Kompetenzprofilen zuzuordnen, bleiben Überschneidungen.

Ausgehend von der Literatur kann Ethical Literacy als Meta-Kompetenz aufgefasst werden. Sie wird als Element jeder anderen Literacy aufgeführt, d. h. die Frage „Was darf ich“ bzw. „Was ist ethisch korrekt“ muss stets mit betrachtet werden. Offensichtlich geht es nicht ohne die ethische Perspektive, sei es bei der Erstellung von Statistiken oder bei jedem anderen Umgang mit Daten und Informationen. So sollten Statistiken nicht bewusst manipuliert werden, um deren Nutzer*innen nicht zu bestimmten Entscheidungen zu verleiten („nudging“). Doch selbst die objektiv korrekte Analyse von Daten kann ethisch fragwürdig sein, wenn sie zu Diskriminierungen führt, etwa bei der unterschiedlichen Preisgestaltung von Krankenversicherungstarifen in Abhängigkeit vom Geschlecht: Obwohl die durchschnittlichen Krankheitskosten von Frauen höher sind, darf deshalb das Geschlecht nach einem Urteil des Europäischen Gerichtshofs nicht mehr als Risikofaktor in die Tarifgestaltung einfließen. Zur Aufgabe, ein solches Risiko-Scoring handwerklich korrekt durchzuführen, gesellt sich also unmittelbar die Herausforderung, die Zulässigkeit des Scorings zu beurteilen, d. h. seinen Gebrauch und potenziellen Missbrauch zu beurteilen. Der Auffassung, dass Data Literacy auch Ethical Literacy erfordert, liegt demnach die Überzeugung zugrunde, dass die Erhebung, Nutzung, Verarbei-

tung und Analyse von Daten nicht kontextunabhängig, d. h. getrennt von deren Interpretation und Anwendung erfolgen kann.

Ethical Literacy im Rahmen von Data Literacy ist insbesondere die Fähigkeit, die Bedeutung von Daten zur Entscheidungsfindung vollständig zu erfassen, indem mögliche Interpretationen dieser Daten in unterschiedlicher Kontextualisierung reflektiert und kritisch bewertet werden.

Information Literacy wird in der Literatur meist als übergreifende, rezep tive Kompetenz aufgefasst, da sich die dort typischerweise genannten Kompetenzen auf den allgemeinen Umgang mit Informationen beziehen, nicht nur auf Daten oder Statistiken. Data Literacy und Statistical Literacy definieren sich als Teilgebiete davon, wobei es Überschneidungen gibt. Data Literacy beschreibt vornehmlich den Umgang mit Daten, also der Beschaffung und Speicherung von Daten, der Datenmanipulation bzw. Datenaufbereitung und der Datenanalyse zum Zweck der Transformation von Daten in Wissen – also den Prozess der Produktion von Wissen aus Daten. Statistical Literacy beschreibt dagegen vornehmlich den Umgang mit vorhandenen Statistiken und die Interpretationsfähigkeit, d. h. den rezep tiven Prozess. Ab einem gewissen Kompetenzniveau können beide Begrifflichkeiten nicht mehr unabhängig voneinander betrachtet werden. Die planvolle Produktion von Wissen aus Daten setzt das Verständnis über die mögliche Rezeption zwingend voraus. Umgekehrt erfordert die datenbasierte Entscheidungsfindung ein Verständnis des datengenerierenden Prozesses, d. h. der Datenherkunft einschließlich möglicher Limitationen, sowie der verwendeten Analysewerkzeuge.

Innerhalb der beiden Kompetenzen lassen sich weitere Subkompetenzen formulieren. Eine Kompetenz, die in den letzten Jahren stark an Bedeutung gewonnen hat, ist die Visual Literacy oder Graph Literacy. Sie beschreibt die Fähigkeit, Visualisierungen korrekt erstellen und interpretieren zu können. Somit ist sie Teil sowohl von Data Literacy als auch von Statistical Literacy. Eben solche Überschneidungen weist die Model Literacy auf. Sie wird als die Kompetenz aufgefasst, die verschiedenen statistischen Modelle hinsichtlich ihrer Verwendungsbereiche, Stärken und Schwächen zu kennen und korrekt anzuwenden sowie zu interpretieren. Computational Literacy schließlich umfasst die Fähigkeit zum allgemeinen Umgang mit Computern sowie Programmierkompetenzen. Sie ist vornehmlich der Data Literacy zuzuordnen; vereinzelt kann auch Statistical Literacy gewisse Kompetenzen der Computational Literacy erfordern, etwa um den Einfluss eines verwendeten numerischen Simulations- oder Optimierungsverfahrens auf ein Analyseergebnis zu beurteilen.

Die vorliegende Studie folgt dem Ansatz, die Kompetenzbegriffe aus Prozessperspektive zu verorten, und vertritt damit die Auffassung von Kompetenzen als Cluster effektiver Verhaltensweisen und Haltungen zur Erfüllung einer abgrenzbaren Aufgabe, d. h. einem Aufgabenkontext. Ausgangsbasis ist ein kombiniertes Prozessmodell, das Münsters Strukturmodell als Grundlage nimmt und Elemente des Pyramidenmodells (Differenzierung zwischen Daten, Informationen und Wissen) sowie Elemente des Pyramidenmodells (Prozessschritte als Kompetenzfelder) integriert. Die Kompetenzbegriffe lassen sich dann hinsichtlich der Merkmale der zugrundeliegenden Aufgabe bzw. Prozessschritte zur Erledigung dieser Aufgabe charakterisieren:

- Sie erfassen einen einzelnen Prozessschritt (punktuell) oder mehrere Prozessschritte (übergreifend). Die Dimension ist in der folgenden Abbildung 5 als „innen – außen“ dargestellt.

- Sie erfassen vornehmlich produktive, kodierende Prozessschritte oder vornehmlich rezeptive, dekodierende Prozessschritte. Die Dimension ist in der folgenden Abbildung 5 als „links – rechts“ dargestellt.
- Sie erfassen Prozessschritte, auf denen Wissen im Mittelpunkt steht, oder solche, auf denen Daten im Mittelpunkt stehen. Die Dimension ist in der folgenden Abbildung 5 als „oben – unten“ dargestellt

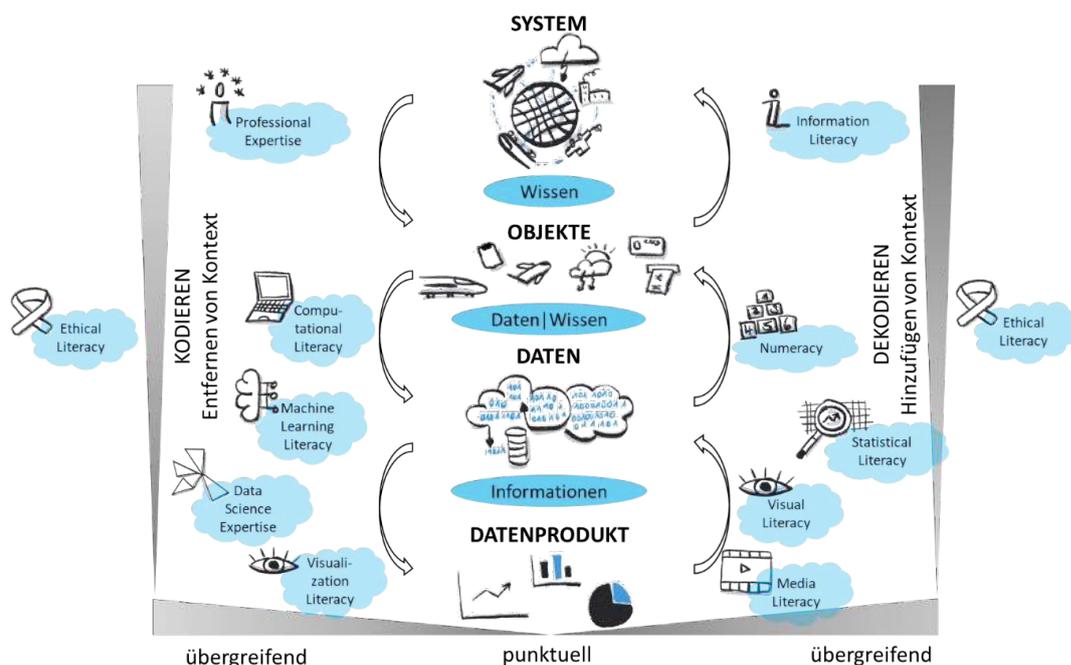


Abbildung 5: Einordnung der Kompetenzbegriffe auf dem dreidimensionalen, integrierten Prozessmodell zur Daten-Wertschöpfung

Visualisation Literacy (in der Literatur teilweise auch Graph Literacy genannt) bezeichnet somit eine Kompetenz, die punktuell dem Prozessschritt der Produktion von Daten-Visualisierungen zugeordnet ist, während Visual Literacy korrespondierend dem Prozessschritt der Rezeption, also der Interpretation von Daten-Visualisierungen zugeordnet ist.

Information Literacy wurde jahrzehntelang vorwiegend als eine rezeptive Literacy definiert und hier entsprechend eingeordnet. Durch die sich ändernden Produktionsbedingungen wissenschaftlicher Publikationen (Web 2.0, Open Science, Open Access) und die damit verbundene Erosion der „Gate-Keeper-Funktion“ von Verlagen wird zunehmend eine produzierende Dimension in der Information Literacy betrachtet und beachtet.

Data Science Literacy wird hier als Data Science Expertise bezeichnet, um zu verdeutlichen, dass es sich um ein Kompetenzprofil eines speziellen Berufs handelt (Professional Expertise) und nicht um eine fächerübergreifende Kompetenz. Dies folgt der Auffassung von Kitchin (Kitchin, 2014). Ethical Literacy nimmt als übergreifende Kompetenz eine Sonderstellung ein.

Die vorliegende Studie definiert im Weiteren den Begriff der Data Literacy sehr umfassend:

Data Literacy ist das Cluster aller effizienter Verhaltensweisen und Einstellungen für die effektive Durchführung sämtlicher Prozessschritte zur Wertschöpfung beziehungsweise Entscheidungsfindung aus Daten.

Eine effektive Durchführung zählt dabei auf das Ziel ein, Wert bzw. Wissen aus Daten zu schöpfen, beantwortet also die Frage, was getan werden muss, um dieses Ziel zu erreichen („die richtigen Dinge tun“). Effiziente Verhaltensweisen und Einstellungen ermöglichen es, dieses Ziel mit möglichst geringem Ressourceneinsatz zu erreichen, beantworten also die Frage, wie das Ziel möglichst optimal erreicht werden kann („die Dinge richtig tun“). Die Bedeutung von Haltung, Werten und Einstellungen für Schlüsselkompetenzen stellt Seidl besonders heraus (Seidl et al., 2018).

3.2 Haltung als Kompetenz

Ein Kompetenzrahmen ist ein Modell zur Beschreibung von effektivem Verhalten in einem gegebenen Aufgabenkontext und umfasst Kompetenzen, deren Definitionen und daraus abgeleiteten Verhaltensindikatoren (= Operationalisierung).

Kompetenzrahmen weisen häufig eine thematische Ordnung auf; so fasst beispielsweise der OECD-Kompetenzrahmen verschiedene Schlüsselkompetenzen in Kompetenzkategorien zusammen („Definition und Auswahl von Schlüsselkompetenzen“, 2005). Das European eCompetence Framework (e-CF) („European e-Competence Framework 3.0“, 2016) ordnet Kompetenzen in Kompetenzfeldern an, definiert jeweils Niveaus in Anlehnung an den Europäischen Qualifikationsrahmen für lebenslanges Lernen (EQR) („Der Europäische Qualifikationsrahmen für lebenslanges Lernen“, 2008) und formuliert jeweils Beispiele von Wissen und Fähigkeiten bzw. Fertigkeiten. So werden für das Kompetenzfeld „Planen“ das Wissen über „Konzepte für Geschäftsstrategien“ als Beispiel für Wissen und die Fähigkeit, „zur Entwicklung der Geschäftsstrategie beizutragen“ als Beispiel für Fähigkeiten genannt.

Der EQR unterscheidet neben Kenntnissen (Theorie- und Faktenwissen) und Fertigkeiten (kognitive und praktische Fertigkeiten bzw. Fähigkeiten) die eigentlichen Kompetenzen (Verantwortung und Selbstständigkeit). Der Deutsche Qualifikationsrahmen hingegen unterscheidet Fachkompetenzen (Wissen und Fertigkeiten) von personalen Kompetenzen (Sozialkompetenz und Selbstständigkeit).

Daran zeigt sich bereits die Problematik der Differenzierung: Verantwortung und Selbstständigkeit im Sinne motivationaler, volitionaler und sozialer Fähigkeiten werden in EQR und DQR als Kompetenzkategorie abgebildet, im e-CF jedoch über die Beschreibung der Kompetenzniveaus. Im dortigen Kompetenzfeld „Planen“ zeigt sich beispielsweise Leistungsniveau 5, indem jemand „weitreichende Führungsstärke [nutzt], um Konsens und Verbindlichkeit des Managements des Unternehmens für die ITK-Strategie zu erreichen“. Eine solche Niveaubeschreibung trennt nicht sauber zwischen Fähigkeit und Bereitschaft, sondern setzt beides voraus. Das Projekt ESCO (European Skills and Competencies of Occupations) der Europäischen Kommission hingegen legt „Haltungen“ bzw. „Einstellungen und Werte“ als eigenständige, allgemeine Kompetenzen fest („ESCO – Skills/Competences - European Commission“, o. J.).

Am Ende ist nicht klar, ob „Knowledge“, „Skills“ und „Values“ verschiedene Dimensionen einer Kompetenz darstellen oder ob es sich um verschiedene Kompetenzkategorien handelt. Die letztgenann-

te Auffassung spiegelt sich in EQR und DQR, die davor genannte im KSAVE Modell und wird auch in der vorliegenden Studie vertreten (Heidrich et al., 2018).

3.3 Ausblick: Ableitung überprüfbarer Lernziele

Sollen aus einem Kompetenzrahmen konkrete und überprüfbare Lernziele abgeleitet werden, so wird häufig auf die Bloomsche Lernzieltaxonomie bzw. deren Überarbeitungen zurückgegriffen, die das Erlernen von Wissen und Fähigkeiten auf sechs Stufen anordnet (Armstrong, 2010). Zudem existieren affektive Lernzieltaxonomien zum Erwerb von Werten, die den Umgang mit inneren Antrieben und Gefühlen in Bezug zu moralischen Normen der Gesellschaft in den Vordergrund stellen. Eine Übersicht zeigt Tabelle 1. Unklar ist jedoch, ob nicht bereits das „Anwenden“ ein „Analysieren“ (d. h. das Erkennen des wesentlichen Problemkerns) voraussetzt wie auch ein „Evaluieren“ (d. h. das Bewerten möglicher Methoden oder Lösungsansätze hinsichtlich ihrer Eignung für das konkrete Problem) und vor allem, ob diese Lernziele erfüllt werden können, wenn es an Haltung fehlt.

Kognitiv (Wissen, Fähigkeiten)	Affektiv (Haltungen, Werte, Ethik)
Wissen von Fakten, Methoden und Theorien des jeweiligen Wissensgebiets	keine Angabe
Verstehen von Zusammenhängen, Erkennen der Bedeutungen der Teilinformationen, Rekombination, Treffen von Voraussagen	Imitation (Erkennen, dass bestimmte Dinge oder Verhaltensweisen von Mitmenschen bewertet werden)
Anwendung des Wissens bei konkreten, bis dahin unbekanntem Aufgaben und Problemstellungen	Wertbeantwortung (Handeln nach erkannten bzw. bekannten Wertevorstellungen)
Analyse von Sachverhalten und Problemstellungen auf wesentliche Elemente	Wertung (Dingen und Handlungen einen (emotionalen) Wert beimessen)
Synthese / kreative Kombination bekannter Informationen	Wertordnung (Aufbau eines individuellen Wertesystems, Hierarchisierung eigener Überzeugungen)
Evaluation / Bewerten von Ergebnissen	Verinnerlichung (Integration des Wertes in die eigene Persönlichkeit)

Tabelle 1: Kognitive und affektive Lernzieltaxonomie (Bloom, 1976; Krathwohl, Bloom & Masia, 1997)

Eine Ableitung von konkreten Lernzielen ist nicht Teil der vorliegenden Studie. Ein Kompetenzrahmen, der Data Literacy als testbare Kompetenz definiert und operationalisiert, bedarf allerdings der folgenden Elemente. Er muss sich erstens mit Wissen als „Rohstoff“ beschäftigen und zweitens mit Fähigkeiten bzw. Fertigkeiten als „Werkzeugen“. Beides zu beherrschen ist die Voraussetzung dafür, Aufgaben effizient zu lösen, d. h. nach Peter Drucker „die Dinge richtig zu machen“ (Drucker, 1963). Drittens muss der Kompetenzrahmen Werte und Haltungen thematisieren, d. h. die Bereitschaft zur Reflexion, um Aufgaben effektiv zu lösen, d. h. „die richtigen Dinge zu machen“.

3.4 Didaktische Umsetzungen in anderen Disziplinen

Entscheidungen sollen in einer Vielzahl von Disziplinen zunehmend datenbasiert getroffen werden, so dass die Frage nach der Interpretation und der Ableitung von Handlungsempfehlungen aus den Daten dort immer wichtiger wird. Die bisherigen Kurse an Hochschulen in den Fachdisziplinen zielen vornehmlich darauf ab, die „Produktion“ von Wissen aus Daten zu vermitteln, also einen Kodierungsprozess. Statistikurse, egal ob in der Medizin, den Sozialwissenschaften oder in den Ingenieursdisziplinen, lehren teilweise noch die Berechnung von Kenngrößen mit Hilfe eines Taschenrechners und konfrontieren die Studierenden mit einer hochgradig abstrahierten Herangehensweise und alltagsfernen Konzepten wie etwa die Wahrscheinlichkeitstheorie. Es verwundert nicht, dass es wenigen Studierenden gelingt, das Erlernete in einer realen Situation anzuwenden, so dass empirische Abschlussarbeiten häufig überhaupt nur mit Hilfe statistischer Berater*innen bewältigt werden können.

Mit fortschreitender Digitalisierung werden nicht nur Datenquellen frei zugänglich (Open Data), sondern verschiedene Anbieter stellen auch Analysewerkzeuge zur Verfügung, die intuitiv und niedrigschwellig die Produktion selbst komplexer Analysen und interaktiver Visualisierungen ermöglichen (z. B. Google Data Studio oder TensorFlow). Es kommt zu einer „Demokratisierung“ der Produktion; der Engpass ist nicht mehr die Fähigkeit, anspruchsvolle Analysewerkzeuge richtig anzuwenden, sondern die richtigen Werkzeuge mit den richtigen Daten anzuwenden.

*Der Schlüssel zur Data Literacy zeigt sich sowohl im kompetenten Umgang mit dem Entfernen von Kontextwissen während der Produktion (Kodierung, Analyse) als auch dem Hinzufügen von Kontextwissen während der Rezeption (Dekodierung, Synthese). Auf der Kodierungsseite zeigt sich Data Literacy in der Bewusstheit, welches Kontextwissen durch den Verarbeitungsprozess entfernt bzw. hinzugefügt wird (z. B. durch die Komprimierung der Rohdaten zu Mittelwerten oder die Wahl einer Visualisierungsform, die bestimmte Dimensionen betont) – und welche Aussage dadurch mit den Daten transportiert wird. Auf der Dekodierungsseite zeigt sich Data Literacy in der Bewusstheit, welche Information in der Statistik / Grafik tatsächlich steckt und welche im Dekodierungsprozess hinzugefügt wird bzw. von Kodierer*innen „erzungen“ wird (z. B. durch eine manipulative Darstellungsform). Beides erfordert ein tiefes und breites Fachwissen in der jeweiligen Disziplin. Zudem erfordert es die Bereitschaft, dieses Fachwissen in Frage zu stellen, falls sich infolge der Analyse von Daten Widersprüche zeigen.*

Es wäre utopisch zu verlangen, dass ein*e einzelne*r Lehrende*r in der Lage sein könnte, den Studierenden eines bestimmten Fachgebiets Data Literacy umfassend zu vermitteln. Zudem entspräche das damit suggerierte Bild, es gäbe so etwas wie eine*n „Data Literacy Expert*in“, der oder die den gesamten Prozess der Wertschöpfung aus Daten allein bewältigen könnte, in keiner Weise der Realität. Komplexe Datenprojekte werden im Team bearbeitet, sie erfordern ein interdisziplinäres und multiprofessionelles Arbeiten, das die Fähigkeit zum Projektmanagement und die Kenntnis organisatorischer, rechtlicher und ethischer Rahmenbedingungen miteinschließt.

„Neben spezialisierten Fachkräften wie den Data Scientists brauchen wir in allen Sektoren Fachkräfte, die über Data Literacy Kompetenzen verfügen“, fordern Kuhn et al. in ihrem Beitrag zum Dossier „Curriculumentwicklung“ des Hochschulforums Digitalisierung (Kuhn et al., 2018). Kitchin (Kitchin, 2014) führt umgekehrt in Anlehnung an Williford und Henry (Williford & Henry, 2014) die „Domain Expertise“ und die „Project Management Expertise“ als Teilbereiche der „Kompetenz zum Aufbau von Daten-Infrastrukturen und zur Durchführung von Big-Data-Forschungsprojekten“ auf,

fordert also für den Data Scientist domänenspezifische Kompetenzen und übergreifende Methoden- sowie Sozialkompetenzen. Dabei thematisiert er auch die Forderung nach einem „starken Streben, auf Ergebnisse hinzuarbeiten, die allen Team-Mitgliedern zugutekommen“.

Ein Kompetenzrahmen für Data Literacy sollte aus diesem Grund auch die Schnittstellen zu den Fachexpert*innen berücksichtigen. Dabei ist zu beachten, dass die Beauftragung von Datenexpert*innen im Zuge eines komplexen Datenprojektes oftmals die professionelle Begleitung durch Datenschutzexpert*innen und Datenethiker*innen erfordert. Die Übergabe schutzwürdiger Daten an Dritte bedarf unter Umständen des Abschlusses einer Auftragsdatenverarbeitung, im Zuge derer aufwändige Datenschutz- und Datensicherheitsmaßnahmen getroffen werden müssen, beispielsweise eine fachgerechte Pseudonymisierung.

In Bezug auf Datenethik schlagen [Schüller & Wrobel, 2018] in Anlehnung an die sieben Thesen zur „Digitalen Fairness“ von Hemel [Hemel, 2016] fünf Gruppen von Leitfragen zur Leitlinie „Achtung der informationellen Selbstbestimmung“ vor, um die „digitale Glaubwürdigkeit“ einer Organisation (dort: einer Kommune) sicherzustellen. Daten werden dabei als eine werthaltige Ressource verstanden, die von Bürger*innen ohne unmittelbare Gegenleistung zur Verfügung gestellt würden, für die er jedoch einen moralischen Anspruch auf Partizipation an den Ergebnissen der Datenleistung erwerbe. Gewisse Interessen stünden möglicherweise in Konflikt, etwa der Wunsch der Bürger*innen auf Transparenz und das Bedürfnis einer Behörde nach Diskretion im Falle von Strafverfolgung.

Kuhn [Kuhn, 2018] tritt entsprechend für einen transdisziplinären Ansatz ein, „der durch die Integration verschiedener Expert*innen die Breite der digitalen Transformation der Medizin widerspiegelt, sich hierbei jedoch klar an der Sichtweise des Arztes orientiert.“ Dies gilt nicht nur für die Lehre, die situative und soziale Kontexte abbilden sollte. Konsequenterweise muss auch die Testung der Lernziele anhand situativer und sozialer Kontexte, also in Form von „authentic assessments“, erfolgen.

Vier derartige situative und soziale Kontexte aus verschiedenen Disziplinen werden in Form von Fallbeispielen innerhalb dieser Studie näher beleuchtet (siehe Anhang 1). Aus solchen Fallbeispielen könnten möglicherweise Testinstrumente entwickelt werden, wenn geeignete Bewertungsschemata zur systematischen Erfassung der Lernziele kombiniert werden

3.5 Verortung in der Literatur

Eine Übersicht der verschiedenen Kompetenzrahmen, die in wissenschaftlichen Artikeln definiert wurden, ist im Dokument „Systematic Review“ dargestellt. Zusätzlich wurde eine Reihe zum Umgang mit Daten zu Rate gezogen, um die einzelnen Kompetenzen und Level genauer zu definieren.

Bei einer genaueren Betrachtung der Kompetenzprofile wird deutlich, dass die Orientierung anhand der einzelnen Analyseschritte ein gängiges Vorgehen darstellt. Zuerst werden Kompetenzen betrachtet, die schon vor der Analyse anfallen, also bei der Datenbeschaffung. Während der Analyse sind andere Kompetenzen vonnöten, die oft ein vertieftes Wissen über statistische Modelle erfordert. Den Kompetenzen zur Kommunikation der Ergebnisse wird weniger Beachtung geschenkt. Dabei sind diese essentiell: Eine falsche oder missverständliche Kommunikation der Daten und Statistiken kann die gesamte Analyse obsolet machen.

Zusätzlich zu den Kompetenzen der Analyseschritte werden allgemein gültige Kompetenzen beschrieben, die sich etwa mit der Datenspeicherung oder ethischen Aspekten beschäftigen. Diese

Kompetenzen sind bei allen Analyseschritten relevant. Weniger Aufmerksamkeit scheint aber den verschiedenen Werkzeugen zuzukommen, die auf Seiten der produktiven Prozessschritte bei den Analyseschritten und Kompetenzen erforderlich sind. Die Beherrschung dieser ist aber eine wesentliche Fertigkeit und muss deshalb bei der Beschreibung der einzelnen Kompetenzen auf verschiedenen Niveaus berücksichtigt werden. So erfordert es ein höheres Kompetenzniveau, wenn eine Analyse mit einem Expert*innen-Tool wie R anstatt mit Excel ausgeführt werden soll. Außerdem ersetzt ein ausführliches Wissen über die verschiedenen Programme und die Implementation von den Algorithmen zunehmend ein detailliertes Wissen über die genauen Formeln der Methoden. Während es zu Zeiten der langsameren Computer unumgänglich war, eine lineare Regression manuell zu spezifizieren oder sogar von Hand zu rechnen, vereinfachen dies heute entsprechende Benutzeroberflächen. Zwar ist ein rudimentäres Wissen über die Funktionalität wichtig, aber bedeutsamer ist es heute, einen guten Überblick über die vielen verschiedenen Techniken zu haben. Die Anzahl an Möglichkeiten ist aufgrund schnellerer Maschinen stark gewachsen, weswegen es wichtig ist, dass man genau abschätzen kann, welche Methode bei welchem Datensatz und bei welcher Fragestellung die besten und belastbarsten Ergebnisse liefert.

Grundsätzlich wird auf Seiten der rezeptiven Prozessschritte wenig Aufmerksamkeit auf die Interpretationsfähigkeit gelegt, die Individuen in Bezug auf Statistiken und andere Datenprodukte besitzen. Dies könnte ein Resultat der begrifflichen Trennung von Data Literacy und Statistical Literacy sein. Wie bereits ausgeführt, erscheint diese Trennung nicht mehr zeitgemäß. Um ein gemeinsames Kompetenzprofil zu erstellen, wurden deswegen auch Kompetenzrahmen und Kompetenzprofile zur Statistical Literacy recherchiert. Ein oft zitierter Rahmen wurde von Watson und Callingham 2003 definiert (Watson & Callingham, 2003) und 2004 weiterentwickelt (Watson & Callingham, 2004). Er beschreibt 6 Kompetenzniveaus für das Interpretieren von und den Umgang mit Daten. Auf unterstem Niveau, idiosynkratisch, verfügt der Nutzer nur über die rudimentärsten statistischen und mathematischen Fähigkeiten. Auf dem nächsten Niveau verfügen Nutzer*innen schon über die Kenntnis einzelner statistischer Begriffe und können grundlegende Tabellen, Graphen und Wahrscheinlichkeitsberechnungen interpretieren. Das dritte Niveau erfordert das Erkennen von Schlussfolgerungen, wenngleich noch ohne Begründungen oder qualitative Verwendung von statistischen Begriffen. Im darauffolgenden Niveau können schon vielfältige Begriffe differenziert verwendet werden und statistische Fähigkeiten bezogen auf Mittelwerte, Wahrscheinlichkeiten und Grapheneigenschaften sind erlernt. Im zweithöchsten Niveau können Nutzer*innen schon einfachere Kontexte in Frage stellen, die nicht über zu komplexe Terminologien und Methoden verfügen. Auf dem höchsten Niveau sind Nutzer*innen fähig, jegliche Texte in Frage zu stellen und auch kleinste Aspekte der statistischen Sprache zu interpretieren.

In Anlehnung an die Literatur sowie die Monografien von Kitchin (Kitchin, 2014) und Berry und Linoff (Berry & Linoff, 2004) ist der Rahmen ebenfalls in Hauptkategorien (Kompetenzbereiche) und Unterkategorien (Kompetenzen) unterteilt, die sich besonders an der Definition von Paul Matthews (Matthews, 2016) orientieren. Dort teilen sich die Kategorien auf in Datenbeschaffung, welche vor der Analyse stattfindet, Datenanalyse und Datenkommunikation, welche nach der Analyse von Bedeutung ist. Zusätzlich werden allgemeine Kompetenzen im Datenmanagement definiert, ebenso wie ethische, rechtliche und soziale Kompetenzen, die auf einer Metaebene lokalisiert werden. Pro Kompetenzfeld werden einzelne Kompetenzen definiert, auf denen jeweils verschiedene Kompetenzniveaus erreicht werden können. Dabei wird unterteilt in Kompetenzen, die auf der Produzent*innenseite erforderlich sind, also im Kodierungsprozess, und Kompetenzen, die auf der Rezipient*innenseite erforderlich sind, also im Dekodierungsprozess. Die in der Literatur häufig separat

betrachteten, ethischen Kompetenzen werden auf beiden Seiten als eine Kompetenzdimension aufgefasst, stellen also eine wesentliche Facette jeder einzelnen Kompetenz im Umgang mit den Daten dar und umfassen Motivation und (Wert-)Haltung. Datenschutz- und Datensicherheitsaspekte werden hingegen in eine Kompetenz im Kompetenzfeld „Daten bereitstellen“ gefasst, da sie dort vornehmlich benötigt werden.

Die Niveaus skizzieren, welcher Grad an Komplexität der dem jeweiligen Prozessschritt entsprechenden Aufgabe von einem Individuum bewältigt werden kann. Während das erste Niveau lediglich ein grundlegendes Wissen und Fähigkeiten hinsichtlich einfacherer Methoden erfordert, lässt sich das höchste Niveau mit dem eines Data Scientists vergleichen. Dabei ist anzumerken, dass es nicht das Ziel ist, dass jedes Individuum das Expert*innenniveau erreichen muss. Stattdessen sollte je nach Disziplin und dessen Berührungspunkten mit Daten ein dort zu definierendes Kompetenzniveau beherrscht werden. Entscheidend ist das Verständnis für die Grenzen der eigenen Kompetenz und die Bereitschaft, bei komplexeren Aufgaben die Meinung von Expert*innen hinzuzuziehen.

Der vorgeschlagene Kompetenzrahmen ist in Relation zu den in der Literatur auffindbaren Beispielen sehr ausführlich und komplex, doch war die Ambition, einen Rahmen vergleichbar dem des standardisierten europäischen Kompetenzrahmens zu gestalten. Die Vorgehensweise bei der Entwicklung des Kompetenzrahmens wurde deshalb angelehnt an die Methodik, die bei vergleichbaren Projekten der Europäischen Kommission, wie etwa e-CF (eCompetence Framework) oder ESCO (European Skills and Competencies of Occupations) angewendet wurde. In der Konsequenz erfordert allerdings auch die Ableitung fach- bzw. studiengangsspezifischer Lernziele, Mess- oder Testinstrumente erheblichen weiteren Entwicklungsaufwand. Hier herrscht klarer Bedarf an zusätzlicher Forschung, die auf den in der vorliegenden Studie erarbeiteten Konzepten aufsetzen sollte.



04

Kapitel 4: Darstellung des Kompetenzrahmens

4.1 Intention und Einsatzmöglichkeit

Der Kompetenzrahmen, im Folgenden als „Data Literacy Framework“ bezeichnet, besteht aus 18 Kompetenzen, die im Prozess der Wertschöpfung beziehungsweise Entscheidungsfindung aus Daten zum Einsatz kommen. Er basiert auf einem einheitlichen, zyklischen Prozessmodell, das die einzelnen Prozessschritte und die korrespondierenden Kompetenzen in produktive und rezeptive Schritte einteilt. Das Data Literacy Framework vermeidet bewusst, Data Literacy als Data Science Expertise (oft irreführend als Data Science Literacy bezeichnet) zu verstehen. Letztere wird vornehmlich den Bereichen Statistik / Mathematik / Informatik zugeordnet, betont die technische Seite der Kompetenzen und entspricht aus Sicht der Verfasser*innen einem berufsspezifischen Kompetenzprofil.

Vielmehr beschreibt der Begriff Data Literacy hier sowohl die Erstellung von Datenprodukten durch den methodisch versierten Fachexpert*innen wie auch den kompetenten Umgang mit Daten durch den Endanwender*innen, d. h. die kritische und adäquate Interpretation und Anwendung der Daten. Entsprechend ist das Data Literacy Framework vornehmlich konzipiert für Hochschulen wie auch andere Bildungsinstitutionen, aber auch für Manager*innen und Personalabteilungen in privatwirtschaftlichen und öffentlichen Organisationen und für politische Entscheidungsträger*innen. Zudem kann das Data Literacy Framework verwendet werden, um Data-Literacy-Kompetenzen für mündige Bürger*innen zu formulieren, wobei in diesem Falle eher niedrige Kompetenzstufen angestrebt werden dürften.

4.2 Gliederungsebenen des Kompetenzrahmens

Das Data Literacy Framework, das vollständig im Anhang 3 wiedergegeben ist, gestaltet sich in vier Gliederungsebenen. Diese geben die unterschiedlichen Ebenen des Prozesses und seiner Prozessschritte wie folgt wieder:

Gliederungsebene 1: 6 Kompetenzfelder, abgeleitet aus den Prozessschritten: (A) Datenkultur etablieren – (B) Daten bereitstellen – (C) Daten auswerten – (D) Ergebnisse interpretieren – (E) Daten interpretieren – (F) Handeln ableiten. Die Kompetenzfelder (A) bis (C) entsprechen den produktiven Prozessschritten vom System zu den Daten zu den Datenprodukten, die Kompetenzfelder (D) bis (F) entsprechen den rezeptiven Prozessschritten von Datenprodukten zu Daten zu System.

Gliederungsebene 2: Wesentliche Kompetenzen für jedes Feld, jeweils mit einer generischen Beschreibung. In Kompetenzfeld (B) wird eine weitere Unterteilung vorgenommen.

Gliederungsebene 3: Beispiele von Wissen, Fähigkeiten/Fertigkeiten sowie Motivation und (Wert-)Haltungen. Die Dimension „Knowledge“ bezieht sich auf die Kenntnisse, die ein Individuum benötigt, um den Prozessschritt zu bewältigen. In dieser Dimension geht es um das [komplexe Fach-]Wissen. Die Dimension „Skills“ beschreibt die Fähigkeiten und Fertigkeiten, die ein Individuum benötigt, um den Prozessschritt zu bewältigen. Diese Fähigkeiten beziehungsweise Fertigkeiten beschreiben die Anwendung des Wissens, also die Abstraktion des Gelernten. Die Dimension „Attitudes, Values, Ethics“ (AVE) beschreibt die Motivation und (Wert-)Haltung, die ein Individuum besitzen sollte. Sie beschreibt die ethischen Ansprüche, etwa um eine gewisse Objektivität sicherzustellen und den Missbrauch von Daten und Analysen auszuschließen. Zusätzlich geht es hier um Leistungsbereitschaft, Offenheit und die Bereitschaft, aus Fehlern zu lernen.

Die Unterteilung in diese drei Dimensionen soll ein umfassendes Bild der Kompetenz ermöglichen. Besonders die AVE-Dimension wird in Kompetenzrahmen häufig vernachlässigt. Zwar werden Werte und Ethik gelegentlich als separate Kompetenz oder als Kompetenzbündel formuliert; die persönliche Haltung des Individuums rückt jedoch selten in den Fokus der Betrachtungen.

Gliederungsebene 4: Niveauspezifikationen, die eine Vereinfachung der EQF-Levels darstellen. EQF-Levels [EQF = European Qualifications Framework] liefern europäische Referenzen für die Komplexitätsniveaus, auf denen eine Kompetenz ihre Anwendung findet. Hier wurden die Kompetenzen auf jeweils drei Komplexitätsniveaus der zugrundeliegenden Anforderungen spezifiziert, die ein „Basis-Niveau“, ein „Fortgeschrittenen-Niveau“ und ein „Expert*innen-Niveau“ grob umreißen sollen. Sie werden über aufeinander aufbauende Anforderungsstufen definiert. Diese Spezifikationen sollten in einer Folgestudie detailliert ausgearbeitet werden, um die Ableitung konkreter Lernziele zu ermöglichen.

4.3 Von der Kompetenzdefinition zum Kompetenzrahmen

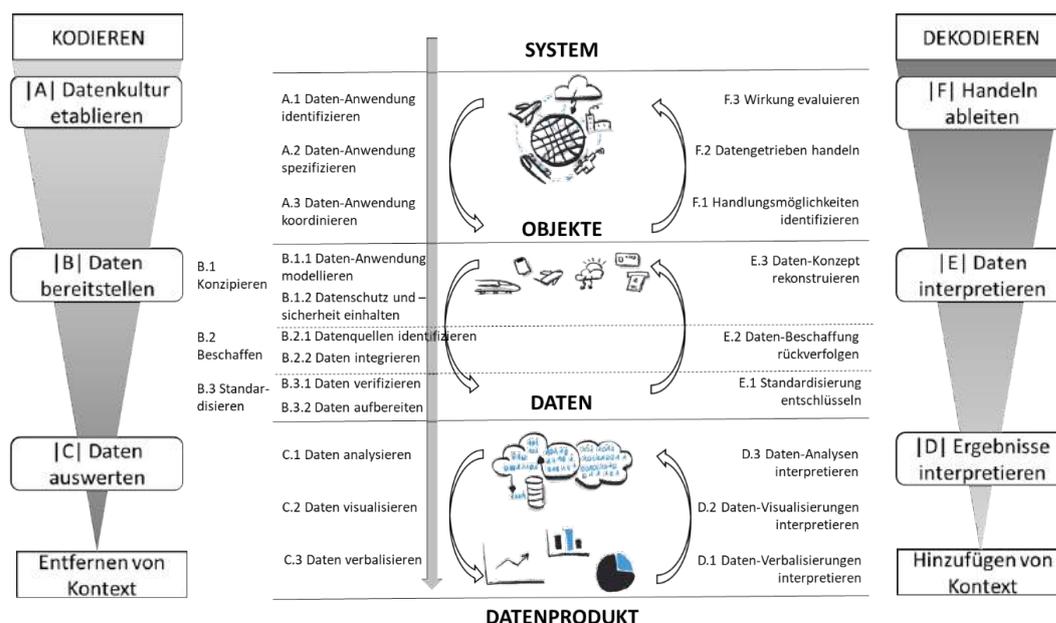


Abbildung 6 Kompetenzfelder und Teilkompetenzen des Data Literacy Frameworks im Prozessmodell der Daten-Wertschöpfung

Das Data Literacy Framework ergibt sich aus einer detaillierten Betrachtung der einzelnen Prozessschritte. Denn der Definition aus Kapitel 3 folgend, ist Data Literacy eben genau das Cluster aller effizienter Verhaltensweisen und Einstellungen für die effektive Durchführung sämtlicher Prozessschritte zur Wertschöpfung beziehungsweise Entscheidungsfindung aus Daten. Zugrunde gelegt wurde die Literatur, die im studienbegleitenden systematischen Review recherchiert, analysiert und bewertet wurde. Zudem sind praktische Erfahrungen aus langjähriger beratender Erfahrung im Berufsfeld „Data Science Consulting“ eingeflossen.

Kompetenzfelder und Kompetenzen

Die Kompetenzfelder „Daten beschaffen“, „Daten auswerten“, „Ergebnisse interpretieren“ und „Daten interpretieren“ mit den dort jeweils genannten Kompetenzen sind im bisher entwickelten Data-Literacy-Kompetenzrahmen typischerweise enthalten. Oft werden die beiden letzten zusammengefasst und nicht ausdifferenziert.

Mandinach und Gummer definieren Data Literacy als die Fähigkeit, Daten zu verstehen und effektiv zu verwenden, um Entscheidungen zu unterstützen (Mandinach & Gummer, 2013). Die von ihnen definierten Skills decken die gesamte Wertschöpfungskette ab, indem sie einerseits den Umgang mit Daten thematisieren, andererseits aber auch einen Fokus auf das Definieren von Hypothesen und die Ableitung von Handlungsmöglichkeiten, das Durchführen und die Analyse der Wirkung setzen.

Die Kernkompetenzen für Data Information Literacy, die von Carlson et al. definiert wurden (Carlson, Johnston, Westra & Nichols, 2013), befassen sich detailliert mit den Fähigkeiten und Fertigkeiten, die auf der Kodierungsseite anfallen und betrachten das ethische Handeln als eigene, wichtige Kernkompetenz. Da dieser Rahmen speziell für das Arbeiten mit Forschungsdaten definiert wurde, wird die Dekodierungsseite hier nicht einbezogen. Die zwölf Kernkompetenzen, die aufgelistet werden, sind in Tabelle 2 dargestellt.

Datenverarbeitung und -analyse	Datenübernahme und -wiederverwendung
Datenmanagement und -organisation	Datenumwandlung und Kompatibilität
Datenschutz	Datenvisualisierung und Darstellung
Datenbanken und Datenformen	Daten finden und erwerben
Ethik und Zuordnung	Metadaten und Datenbeschreibungen
Datenqualität und Dokumentation	Verfahrensoptionen

Tabelle 2: Kernkompetenzen von Carlson et al.

Das Kompetenzfeld „Datenkultur etablieren“ behandelt Sternkopf in ihrem Data Literacy Reifegradmodell. Ebenso finden sich Hinweise darauf bei Kitchin (Kitchin, 2014), Goldsmith & Crawford

(Goldsmith & Crawford, 2014) und bei Schüller und Wrobel (Schüller & Wrobel, 2018). Kitchin sowie Williford & Henry betonen insbesondere die Interdisziplinarität und die daraus resultierende Notwendigkeit eines Datenprojektmanagements. Das inkludiert die Kenntnis und Beherrschung entsprechender Werkzeuge (z. B. Git). Wrobel & Schüller thematisieren an einem Praxisbeispiel auch das Kompetenzfeld „Handeln ableiten“ und die Haltung, die es benötigt, um datengetriebene Entscheidungen im Zuge der digitalen Transformation in einer Organisation zu etablieren.

(Wert-)Haltung als Kompetenzdimension

Ausschlaggebend für die Entscheidung, die Dimension (Wert-)Haltung und Motivation durchgehend als Kompetenzdimension zu integrieren, war die Tatsache, dass Datenanalyse und -Interpretation – im Gegensatz zu Mathematik oder Programmierung – keine eindeutige Transformation darstellt. Auf dem Weg vom System zum Datenprodukt wird vielmehr laufend Kontextwissen entfernt (Extraktion der „wesentlichen“ Informationen), auf dem Weg zurück wird laufend Kontextwissen hinzugefügt (Interpretation und Kontextualisierung). Ein wesentlicher Lernfortschritt in der Dimension der (Wert-) Haltung ist es zu verinnerlichen, dass dahinter stets ein Bewertungsprozess liegt und dass bei dieser Bewertung etwas schief gehen kann, versehentlich oder mit Absicht. Dazu gehört auch das Bewusstsein, dass ein Ressourceneinsatz erfolgt: Um Datenprodukte zu erzeugen, investiert man Arbeitskraft, physische Energie, und beansprucht Ressourcen, die einem womöglich gar nicht gehören.

Auf der Seite der Produktion bedeutet ethische Grundhaltung insbesondere abzuwägen, was die Daten wirklich beinhalten, was nicht und wann das gar nicht beurteilt werden kann (d. h. wo Grauzonen liegen). Sich bewusst zu sein, dass die Datenanalyse zu einem bestimmten Zweck durchgeführt wird (und damit zwangsläufig gewisse Interessen verbunden sind, denen man unter Umständen auch verpflichtet ist) ist Ausdruck von Haltung und Reflexionsfähigkeit.

Auf der Seite der Rezeption bedeutet kritische Grundhaltung: sich bewusst zu machen, dass man in der Interpretation eigenes Vorwissen und eigene Wertvorstellungen einfügt und dass beides subjektiv ist. Zudem gilt es zu verinnerlichen, dass es subtile Manipulationsmöglichkeiten durch den oder die Produzent*in gibt und wie diese gegebenenfalls die eigene Interpretation beeinflussen kann. Zur Haltung gehört auch, sich bewusst zu machen, dass man mit eigenen inneren Widerständen umgehen muss, wenn die Daten nicht das gewünschte Ergebnis liefern – und dass man deshalb dem Impuls, die Ergebnisse abzulehnen, nicht sofort nachgeben sollte. Umgekehrt gilt dies genauso, falls die Ergebnisse die eigenen (Vor-) Urteile bestätigen – dennoch gehören sie kritisch hinterfragt. Die Verantwortung für Entscheidungen unter Unsicherheit kann und darf schließlich nicht an die Datenanalyse delegiert werden.

4.4 Beispiel einer Kompetenz im Detail

Die folgende Tabelle 3 ist dem neu entwickelten Data Literacy Framework (siehe Anhang 3) entnommen und beinhaltet die Ausformulierung der Kompetenz C.1: Daten analysieren (produktiver Prozessschritt) und der korrespondierenden Kompetenz D.3: Datenanalysen interpretieren (rezeptiver Prozessschritt).

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
C.1: Daten analysieren	Setzt Analyseverfahren aus verschiedenen Gebieten (Statistik, Analytics, Machine Learning), unter Zuhilfenahme der geeigneten Werkzeuge sach- und zweckorientiert ein	Kenntnis von Verfahren für unterschiedliche Aufgaben (Deskription, Exploration, Prognose) sowie über deren Voraussetzungen, Stärken und Schwächen	Fähigkeit, messbare Beziehungen in Modellen abzubilden	Bereitschaft, in einem iterativen und oft zeitaufwändigen Prozess Modelle zu implementieren und anzupassen	(1) Kann mit grundlegenden statistischen Methoden wie etwa Mittelwert und Standardabweichung umgehen
		Wissen über Verfahren für gerichtete und ungerichtete Fragestellungen	Fähigkeit, anhand der jeweiligen Fragestellung und der verfügbaren Daten geeignete Analyseverfahren zu identifizieren und auszuwählen	Skeptische Grundhaltung bei der Datenanalyse	(2) Beherrscht und verwendet auch komplexere Modelle, kann einschätzen, welche Methoden für welche Fragestellungen und Daten sinnvolle Ergebnisse liefern und erkennt die Grenzen der Analyseergebnisse
		Wissen über Schätzverfahren und Algorithmen	Fähigkeit, das Modell geeignet zu spezifizieren (z. B. durch Festlegung von Optimierungskriterien)	Bereitschaft, Informationsverluste im Prozess der Analyse abzuwägen und zu akzeptieren	
		Wissen über Möglichkeiten der Modelldiagnostik und der Modelloptimierung	Fähigkeit, das Modell auf Schwächen und Artefakte (z. B. Overfitting, Multikollinearitätsprobleme) zu untersuchen und diesen entgegenzuwirken	Bereitschaft, „Good Analytics Standards“ einzuhalten, selbst wenn diese nicht explizit definiert sind	
		Wissen über Maßnahmen, um die Robustheit und allgemeine Gültigkeit der Modelle			(3) Beherrscht und verwendet hochgradig komplexe Modelle und erkennt, wenn die Analyse keine sinnvollen Ergebnisse liefern kann bzw. wann die Informationen der Analyse keine

<p>C.1: Daten analysieren</p>	<p>Setzt Analyseverfahren aus verschiedenen Gebieten (Statistik, Analytics, Machine Learning), unter Zuhilfenahme der geeigneten Werkzeuge sach- und zweckorientiert ein</p>	<p>sicherzustellen (z. B. Kreuzvalidierung) Wissen über mögliche Ursachen von Artefakten</p> <p>Wissen über Best Practices und Standards der Modellentwicklung und Datenanalyse, z. B. Validierung</p> <p>Wissen, dass bei der Analyse von Daten Information verloren geht und dass ein Auswahl- und Bewertungsprozess nötig ist, auf welche Information verzichtet werden kann</p>	<p>Fähigkeit, die Unsicherheit der Modell-ergebnisse zu beurteilen und die benötigte Genauigkeit zu bestimmen</p> <p>Fähigkeit, zukünftige Nutzungen der Analyseergebnisse zu antizipieren</p> <p>Fähigkeit, relevante von irrelevanten Informationen im Analyseprozess zu trennen (z. B. Variablen zu selektieren)</p>	<p>Bereitschaft, ressourcenschonend zu arbeiten, z. B. das Modell nicht zu „Over-Engineeren“</p> <p>Bereitschaft, die benötigte Präzision auch bei knappen Ressourcen und gegen Widerstände durchzusetzen, um Trugschlüsse zu verhindern</p> <p>„Analytical Fairness“ als Grundhaltung, d. h. Bereitschaft, Analysen nicht durchzuführen, wenn das Risiko eines Missbrauchs hoch ist</p> <p>Objektivität als Grundhaltung, insbesondere in Situationen, in denen Datenlage und Fragestellung Spielraum für die Analyse lassen</p>	<p>Relevanz für die Fragestellung haben und der Analyseprozess beendet werden sollte</p>
<p>D.3: Daten-Analysen interpretieren</p>	<p>Interpretiert Datenprodukte (Statistiken, Modellergebnisse) in verbalisierter Form bzw. prüft kritisch die explizit oder implizit gelieferte Interpretation</p>	<p>Wissen über statistische Kennzahlen wie Mittelwerte, Prozente, Prozentpunkte, deren Aussagekraft und Einschränkungen</p> <p>Wissen über Zusammenhänge zwischen statistischen Kennzahlen und den zugrundeliegenden Daten</p>	<p>Kann Schlüsse ziehen, über welche Charakteristika der Daten eine Kennzahl Aussagen trifft</p> <p>Versteht, welche Kennzahlen (auch verbalisiert) äquivalent verwendet werden</p>	<p>Bereitschaft, explizit kommunizierte, vorgegebene Interpretationen in Daten-Verbalisierungen zu hinterfragen</p> <p>Bereitschaft, nach implizit kommunizierten Interpretationen zu suchen und diese zu hinterfragen</p>	<p>[1] Kann einfache statistische Terminologie verstehen und deren Bezug zu den Daten interpretieren, kennt grundlegende Formen der Manipulation durch Statistiken und Berichte und die zu beachtenden Kriterien</p>

<p>D.3: Daten-Analysen interpretieren</p>	<p>Interpretiert Datenprodukte (Statistiken, Modellergebnisse) in verbalisierter Form bzw. prüft kritisch die explizit oder implizit gelieferte Interpretation</p>	<p>Wissen über den Bezug zwischen Kennzahlen (z. B. relative/absolute Häufigkeiten)</p> <p>Wissen, dass die Wahl einer bestimmten Kennzahl das Ergebnis eines bewussten Entscheidungsprozesses sein kann</p> <p>Kenntnis statistischer Fachbegriffe</p> <p>Kenntnis statistischer Fehlschlüsse (z. B. Korrelation vs. Kausalität)</p> <p>Wissen, dass statistische Aussagen i. d. R. keine Einzelfallaussagen darstellen</p> <p>Wissen, dass die Interpretation das Hinzufügen von Kontextinformation erfordert</p>	<p>Kann hinterfragen, ob spezielle Datensituationen das Ergebnis beeinflussen</p> <p>Kann hinterfragen, ob die Darstellungsform die Aussage eines Datenprodukts beeinflusst</p> <p>Kann hinterfragen, inwiefern die Interpretation der Ergebnisse vom eigenen Kontextwissen abhängt</p> <p>Kann hinterfragen, inwiefern die Darstellung der Ergebnisse durch die Wahl der Form (z. B. Prozente) oder die Verbalisierung die Interpretation manipulativ beeinflusst</p>	<p>Bereitschaft, das eigene Kontextwissen in Bezug auf dessen Einfluss auf die Interpretation zu hinterfragen</p> <p>Offenheit gegenüber neuen Erkenntnissen, auch wenn diese den bisherigen Überzeugungen widersprechen</p> <p>Bereitschaft, die Bedeutung der Ergebnisse für den Sachverhalt, in den sie gestellt werden, zu hinterfragen</p>	<p>(2) Besitzt ein fortgeschrittenes Verständnis der Terminologie und kann zwischen verschiedenen Begriffen sauber differenzieren, kennt Bausteine expliziter Kommunikation und kann prüfen, ob explizite Interpretationen aus den Ergebnissen ableitbar sind</p> <p>(3) Besitzt ein vertieftes Verständnis der Terminologie, kann implizite Aussagen und Interpretationen erkennen, und zueinander sowie in Bezug auf den Sachverhalt abwägen und beurteilen</p>
---	--	---	--	---	---

Tabelle 3: Ausschnitt aus dem Data Literacy Kompetenzrahmen (Kompetenzen C.1 und D.3)



05

Kapitel 5: Messung und Testung von Data Literacy

5.1 Einordnung der Mess- und Testinstrumente

Während sich die vorangegangenen Kapitel mit der Entwicklung eines Kompetenzrahmen für Digital-Kompetenzen am Beispiel von Data Literacy beschäftigt haben, soll im Folgenden die Messung von Wirkung und Qualität von Lehre und Studium im digitalen Zeitalter sowie auch die Testentwicklung für Digitalkompetenzen am Beispiel von Data Literacy vorbereitet werden. Der Stand der Forschung hierzu ist im zweiten Arbeitspapier der vorliegenden Studie, dem Systematic Review (Schüller et al., 2019a), dokumentiert. Die verschiedenen Mess- und Testinstrumente, die im Zuge des Systematic Review gesammelt wurden, wurden mithilfe des Stufenmodells „The Kirkpatrick Four Levels“ gegliedert, um zu systematisieren, welche Stufe des Lernens evaluiert wird („The Kirkpatrick Model“, o. J.). Das Stufenmodell lässt sich folgendermaßen gliedern:

1. **Reaktion.** Wie motiviert sind die Lernenden, welche Einstellung haben sie zum zu Erlernenden? (Reaction: Did they like it?)
2. **Lernerfolg.** Was wurde gelernt? Kann Wissen, Fähigkeiten und Einstellung umfassen. (Learning: Did they get it?)
3. **Verhalten.** Können die Lernenden das Gelernte tatsächlich anwenden? (Behaviour: Can they do it?)
4. **Ergebnis.** Was hat das Erlernete verändert, z. B. hinsichtlich Werten oder hinsichtlich einer Verbesserung der Aufgabenerfüllung? Was für einen Einfluss hat das Erlernete auf die intrinsische Motivation der Person? (Results: Does it matter?)

Bei dieser Einteilung zeigte sich, dass die ersten zwei Stufen von den gesammelten Instrumenten sehr gut abgedeckt werden können; die dritte Stufe wird zwar laut Einschätzung in der Literatur von einigen Instrumenten erfasst¹, aber intrinsisch motiviertes Verhalten kann mutmaßlich in einer Testsituation nur schwer beobachtet werden. Die letzte Stufe ist mit den dokumentierten Instrumenten nicht erfassbar, da sich die Wirkung auf das System, die aus der Kompetenzbildung resultiert, nicht messen lässt. Eine solche Wirkung bestünde beispielsweise darin, dass eine Stadtverwaltung bessere Entscheidungen hinsichtlich der integrierten Stadtentwicklung trifft, weil ihre Mitarbeiter*innen Data Literacy aufbauen, oder dass mehr Data Literacy der Ärzt*innen zu einer Verringerung der falsch positiv diagnostizierten und unnötig behandelten Brustkrebspatient*innen führt.

Die Fähigkeit und Bereitschaft, das Erlernete anzuwenden (Stufe 3), lässt sich beispielsweise in Form einer Hausarbeit überprüfen. Ob das Verhalten aber aufgrund einer extrinsischen Motivation gezeigt wird, wie etwa aufgrund der Anreizwirkung einer guten Note, oder tatsächlich auch aus einer intrinsischen Motivation heraus und ob das Erlernete auch außerhalb der Hochschule einen Einfluss

¹ (Erlinger 2018) meint, man könne Verhalten mit verschiedenen Assessment-Typen prüfen, aber mutmaßlich gilt das streng genommen nur für extrinsisch motiviertes Verhalten.

auf das Verhalten und die Einstellung der Studierenden besitzt, kann nicht getestet werden. Zusätzlich werden die Lernstufen in Beziehung gesetzt zu kognitiven und affektiven Lernbereichen und die Testinstrumente entsprechend kategorisiert. Während sich das Kognitive auf das Wissen und die Fähigkeiten bezieht, thematisiert das Affektive die Haltung, Werte und Ethik.

Die folgende Abbildung 7 veranschaulicht das Ineinandergreifen von Lernbereichen, Kompetenzdimensionen und Lernstufen. Es ist wie oben bereits erläutert davon auszugehen, dass sich das Erlernen von (Wert-)Haltungen, Wissen und Fähigkeiten gegenseitig beeinflusst. Dass ein Instrument eine Dimension, unabhängig von den anderen, messen oder testen kann, ist wohl eine grobe Vereinfachung. Um eine Vorauswahl geeigneter Instrumente zu treffen, kann dieser Aspekt jedoch außer Acht gelassen werden.

Für die Einordnung in das Lernstufen-Modell und die weitere Vorauswahl empfiehlt es sich, die gefundenen Instrumente weiter zusammenzufassen und danach zu unterscheiden, ob sie qualitativ oder quantitative Verfahren darstellen und ob sie standardisierte („künstliche“) Testsituationen abbilden oder authentische Evaluationsformen darstellen, also eine reale Situation zum Ausgangspunkt nehmen.

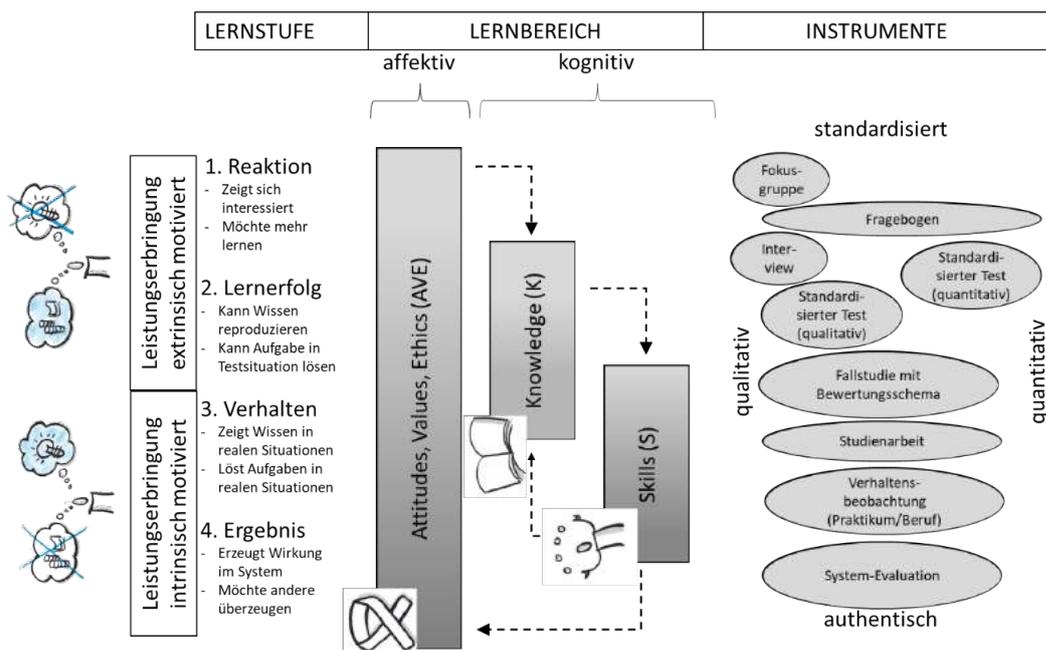


Abbildung 7: Einordnung der Instrumente in das Lernstufen-Modell

5.2 Ergebnisse der Literaturanalyse

In der Literatur werden viele mögliche Testverfahren dokumentiert, um die verschiedenen Literacies zu testen. Besonders oft thematisiert ist dabei die Information Literacy, wobei sich die Beispiele häufig auf Studierende beziehen. In der Literaturrecherche wurde grundsätzlich nach Testverfahren gesucht, die der oben hergeleiteten Definition von Data Literacy entsprechen und so im Zusammenhang mit dem entwickelten Kompetenzrahmen stehen. Dabei wurde der Schwerpunkt auf standardisierte Tests gelegt, was die Testung von Wissen und Fähigkeiten betrifft; außerdem wurden authentische Evaluationsverfahren näher betrachtet, um sich der Dimension der Haltung zu nähern.

5.2.1 Objektive Testverfahren: Multiple-Choice-Tests

Eine außerordentlich verbreitete Methode, Wissen abzufragen, ist ein einfacher Multiple-Choice-Fragetest. So definieren etwa Jenny et al. (Jenny, Keller & Gigerenzer, 2018) einen Fragebogen mit zehn Fragen, der grundlegende statistische Kenntnisse abfragt. Ein ausführlicher Multiple-Choice-Test ist der Information-Literacy-Test von Swain und Clarke (Swain & Clarke, 2014), der über eine Dauer von 60 Minuten geht und das Wissen der Testpersonen über vier der fünf Kompetenzstandards von Information Literacy testet. Speziell die Visual Graph Literacy wird zum Beispiel im Zuge des GED Tests („GED Practice Questions | Free GED Practice Tests“, o. J.), ebenfalls im Multiple-Choice-Format, getestet. Im Science- und im Social-Studies-Teil werden der Testperson Datenvisualisierungen gezeigt und Fragen dazu gestellt. Je nach Level variiert die Schwierigkeit. Auch der Data Literacy Test von CAVORIT (CAVORIT, o. J.) testet die Visual Literacy im Multiple-Choice-Format, indem er teils sehr komplexe, nicht intuitive Datenvisualisierungen zeigt und basierend darauf Aussagen anbietet, was man aus dieser Visualisierung herauslesen kann. Die Testperson wählt dann aus, ob diese Aussagen wahr oder falsch sind.

Das einfache Multiple-Choice-Testverfahren bietet sowohl Vor- als auch Nachteile (Goldhammer, Kröhne, Keßel, Senkbeil & Ihme, 2014). So ist ein solcher Test schnell zu beantworten und standardisiert auszuwerten. Sofern der Test validiert ist, lassen sich die einzelnen Fragen leicht den einzelnen Kompetenzen zuordnen, weswegen sich unmittelbar Stärken und Schwächen der getesteten Personen ausmachen lassen. Allerdings fragt der Test nur Wissen ab (das unter Umständen extra für den Test auswendig gelernt wurde) und kann kaum in die Tiefe gehen. Deswegen schlägt die Literatur mehrere Möglichkeiten vor, die einfache Wissensabfrage der Multiple-Choice-Tests zu erweitern und die Tests somit komplexer zu gestalten.

Der Berlin Numeracy Test, definiert von Cokely et al., kann beispielsweise im Multiple-Choice-Format verwendet werden, es gibt aber auch eine Version, in der die Testperson selbst Ergebnisse berechnen muss (Cokely, Galesic, Schulz, Garcia-Retamero & Ghazal, 2012). Treagust definiert ein Testverfahren, das auf einem zweistufigen Multiple-Choice-Test basiert (Treagust, 1988). Im ersten Schritt wird, wie bisher mit einer Multiple-Choice-Frage, reines Faktenwissen abgefragt. Dieser Frage folgt aber immer eine zweite Frage, ebenfalls im Multiple-Choice-Format, in der der oder die Getestete begründen muss, warum er oder sie sich für die Antwort in der ersten Frage entschieden hat. Somit fragt der Test nicht nur Faktenwissen, sondern auch dessen Verständnis ab. Ein drittes Testformat verwendet der Situational Judgment Test (SJT). Dieser wurde erstmals definiert von Motowidlo et al. (Motowidlo, Crook, Kell & Naemi, 2009). Der Test ist ebenfalls im Multiple-Choice-Format, aber anstatt einer Wissensfrage wird eine Situation geschildert, zu welcher wiederum vier Handlungsmöglichkeiten vorgeschlagen werden. Je nach Gestaltung muss die Testperson die verschiedenen Möglichkeiten auf einer Likert Skala bewerten oder diejenige Möglichkeit wählen, die beschreibt, wie sie in dieser Situation agieren würde. Der Vorteil eines solchen Testformates ist, dass nicht nur Wissen, sondern auch dessen Anwendung getestet wird. Der Test wurde allgemein entwickelt und in den verschiedensten Bereichen verwendet. Rosman und Mayer entwickelten basierend auf diesem Verfahren 2016 den PIKE-P Test, der gezielt prozedurales und deklaratives Wissen in der Information Literacy testet (Rosman, Mayer & Krampen, 2016).

Der Test zur Data Literacy der Campaign for Data Equality („Qlik | Data Equality Campaign“, o. J.) kann online bearbeitet werden und ist im Multiple-Choice-Format gestaltet. Allerdings fragt er kein Wissen ab, sondern basiert auf der Selbsteinschätzung der Testpersonen, anhand welcher er die Einstellung zu Daten ausgibt.

Eine Variante beinhaltet der General Management Admission Test (GMAT), der als standardisierter, computergestützter, adaptiver Test Teil des Zulassungsverfahrens an vielen, insbesondere US-amerikanischen, Hochschulen ist, einen internationalen Vergleich der Testleistungen bietet und in verschiedenen Formaten verbale Ausdrucksfähigkeit und analytische Fähigkeiten testet („Quantitative Reasoning Section“, o. J.). Der analytische Teil fragt im Format „Problem Solving“ nach der Lösung einer Aufgabe, wobei fünf Antworten vorgegeben sind. Der Fragetypus „Data Sufficiency“, der auf rund die Hälfte aller GMAT-Mathematik-Fragen angewendet wird, ist grundsätzlich anders als vertraute Prüfungsfragen im akademischen Umfeld. Hierbei wird nicht nach der Lösung der Aufgabe gefragt, sondern lediglich danach, ob man die Aufgabe mit den gegebenen zwei unterschiedlichen Informationen lösen kann.

Der verbale Teil des GMAT prüft neben englischer Grammatik vor allem die Fähigkeit, logische Zusammenhänge zu erkennen und Informationen schnell und effizient zu verarbeiten. Die Fragen innerhalb dieses Teils umfassen Aufgaben zu Critical Reasoning, Sentence Correction und Reading Comprehension. Critical-Reasoning-Fragen sollen die Fähigkeit testen, logische Argumentationsketten nachzuvollziehen. Die Fragen bestehen jeweils aus einem kurzen Statement (oder Hypothese) einer Frage und fünf Antwortmöglichkeiten. Es wird in Zusammenhang mit dieser Hypothese nach Schlussfolgerungen („must be true“), nach Annahmen beziehungsweise Voraussetzungen („assumption“), nach dem stärksten Pro- oder Contra-Argument („strengthens/weakens“), nach der Kernaussage („main point“), nach möglichen Widersprüchen („paradox“) und nach dem Aufbau der Argumentationskette („reasoning“) gefragt.

In den Sentence-Correction-Aufgaben muss die Grammatik geprüft werden. Die Reading-Comprehension-Aufgaben präsentieren einen kurzen Text und Aussagen dazu, die mittels Multiple Choice beantwortet werden müssen, wobei hier der Zeitdruck (zwei Minuten pro Frage) besonders stark aufgebaut wird, so dass zugleich die Beherrschung von Techniken zur raschen Informationsverarbeitung getestet wird.

5.2.2 Interpretative Testverfahren: Rubriken/Bewertungsschemata zu Studienarbeiten/Essays

Ein qualitatives Testverfahren wird von Davida Scharf vorgestellt (Scharf, Elliot, Huey, Briller & Joshi, 2007). Anstatt die Studierenden direkt Tests machen zu lassen, analysiert sie die Abschlussarbeiten der Studierenden von Pflichtseminaren, in denen die Grundlagen der Information Literacy unterrichtet wurden. Für diese Performanz-Analysen werden standardisierte Bewertungsschemata angewandt, etwa das Rubriken-System, beschrieben von Megan Oakleaf (Oakleaf, 2009). Die einzelnen Bewertungskriterien werden in Matrixform dargestellt und können in Kompetenzen unterteilt werden, wodurch eine detaillierte Analyse möglich ist.

Beile beschreibt Rubriken zur Bewertung der Quellenrecherche in Studienarbeiten wie Einzel- oder Gruppenpräsentationen, Forschungsprojekten, Hausarbeiten oder Postern (Beile, 2008). Dabei werden akademischer Wert, Verbreitung und Angemessenheit der Quelle in Bezug auf die Aufgabenstellung beurteilt. Die Grundlage der Bewertung ist jeweils eine Schlüsselfrage. Auch für Literaturanalysen existieren solche Rubriken. Kriterien sind dabei etwa die Unterscheidung zwischen notwendigen und optionalen Aufgabenelementen, die Analyse der relevanten Aspekte, die Synthese neuer Aspekte, die Identifikation von Beziehungen zwischen verschiedenen Ideen, die Herstellung von Kontext und andere.

Der GMAT beinhaltet zudem ein Essay, für dessen Ausformulieren 30 Minuten zur Verfügung stehen. Der Text wird direkt am PC eingegeben und später von einem Computerprogramm und einem Korrekturleser mit Hilfe eines Bewertungsschemas gleichrangig bewertet; dieses ist nicht öffentlich verfügbar. Die Analysis-of-an-Argument-Aufgabe verlangt rund 300-500 Wörter. Dabei sollen verschiedene Gesichtspunkte beziehungsweise Positionen zu einem gegebenen Argument prägnant formuliert werden. Ziel ist nicht die Ausführung der eigenen, sondern die kritische Beleuchtung des Textes. Das Ziel ist es, möglichst schlüssig darzulegen, welche Annahmen außer Acht gelassen wurden und wie die Position besser hätte vertreten werden können.

5.2.3 Vom einfachen Test zu multiplen Methoden

Weitere mögliche Formate finden sich bei Leichner, der ein Testverfahren bestehend aus einer Multiple-Choice-Komponente, einer schriftlichen zu beantwortenden Frage und einer Literaturrecherche als Aufgabe vorschlägt (Leichner, Peter, Mayer & Krampen, 2013). Diesen Vorschlag arbeitet Leichner mit Mayer aus, indem er die Rechercheaufgaben näher präzisiert (Leichner, Peter, Mayer & Krampen, 2014). Mit Hilfe einer Screen Capture Software kann das genaue Vorgehen der Studierenden festgestellt werden. Durch dieses Testverfahren können nicht nur die genauen Kompetenzen der Studenten gemessen werden, im Nachhinein können ihnen auch Vorschläge zur Verbesserung der Kompetenzen gemacht werden.

Erlinger führt aus, dass Information Literacy zunehmend mit multiplen Methoden gemessen wird (Erlinger, 2018). Die Hypothese, dass grundsätzlich eine Verschiebung in Richtung authentischer Evaluation erfolge, sei nicht haltbar, vielmehr würden Testverfahren kombiniert und unterschiedliche Lernstufen auf einmal evaluiert.



06

Kapitel 6: Reflexion und Ausblick

6.1 Diskussion mit Fachexpert*innen, Hochschulprofessor*innen und Führungskräften

Die Diskussion mit Fachexpert*innen bestätigt die Notwendigkeit einer klaren Begriffsdefinition. „Data Literacy“ wird offenbar als Begriff an den Hochschulen bislang kaum verwendet, wohl aber im übertragenen Sinne, da Datenkompetenzen aktuell an Bedeutung an der Hochschule zulegen.

6.1.1 Veränderte Bedeutung von Data Literacy

Eine Hochschule plane derzeit konkret einen Masterstudiengang „Data Science“, in dem über das ganze Curriculum als Querschnittsthema quasi „Denken in Daten“ gelegt sei (Statistik-Professor/Volkswirt, Dekan des Fachbereichs Wirtschaft, Fachhochschule). Das Thema wird nach einhelliger Aussage deutlich an Bedeutung zunehmen.

Ein Professor für Unternehmensforschung (Wirtschaftswissenschaftler) kommentiert: „Der Begriff taucht bisher nicht auf, höchstens in Gastvorträgen.“ Datenkompetenzen oder vielmehr deren Fehlen zeigten sich überwiegend bei der Auswertung von Modellergebnissen. Hier zeige sich, dass sowohl bei Masterstudierenden als auch Doktorand*innen die statistischen Grundlagen sehr schwach seien. Hypothesentests würden auswendig gelernt, aber nicht immer verstanden. In den letzten drei Jahren zeige sich zudem ein großes Interesse an Algorithmischer Datenanalyse, also der Verarbeitung von großen Datenmengen.

Ein Professor für Raumentwicklung einer Technischen Universität antwortet: „Mein Fachgebiet Raumentwicklung untersucht funktionale Zusammenhänge von sozioökonomischem Verhalten im Raum. Wir arbeiten mit dem Konzept des systemischen Denkens und von Wertschöpfungsketten von Unternehmen, die funktional an unterschiedlichen Standorten angesiedelt sind. Im Prozess von „Analyse“ zu gestaltenden „Empfehlungen“ nutzen wir den Dreiklang von Daten > Information > Wissen. Räumliche Daten werden bislang v. a. hoheitlich bereitgestellt, genügen in ihrer räumlichen Auflösung nicht mehr unserem raumbezogenem Verständnis von handelnden Akteuren. Wir generieren daher durch Primärerhebung eigene, georeferenzierte Unternehmens- und Haushaltsdaten. Literacy bedeutet hier, dass genau verstanden werden muss, wie das Datum entsteht, welcher Sachverhalt zugrunde liegt, welche impliziten Temporalitäten mitschwingen, um am Ende die daraus aufbereiteten Informationen auch zielgerichtet und handlungsleitend interpretieren zu können.“

Die Wahrnehmung in technischen beziehungsweise Ingenieursstudiengängen scheint eine gänzlich andere. Ein Befragter, Maschinenbau-Professor an einer Fachhochschule, schreibt: „Den Begriff „Data Literacy“ habe ich im Zusammenhang mit meinem Fachgebiet, der Produktentwicklung, aber auch im Maschinenbau generell, noch nicht wahrgenommen. Das kann aber daran liegen, dass englische Begriffe im Maschinenbau keine große Bedeutung haben. In einigen Bereichen des Maschinenbaus ist die Sammlung und Verarbeitung von Daten bereits seit Jahren Stand der Technik, beispielsweise bei der Überwachung und Steuerung von automatisierten

Fertigungsanlagen oder in der Qualitätssicherung. Hier spielt die Datenkompetenz bereits jetzt eine große Rolle, wobei noch deutlich mehr Nutzen aus den Daten gezogen werden könnte. Daher wäre auch hier mehr Datenkompetenz sinnvoll, besonders gemäß der Definition der Studie, also vor dem Hintergrund einer möglichen Wertschöpfung. Die technischen Entwicklungen der letzten Jahre, beispielsweise durch die zunehmende Vernetzung (Internet of Things) und die neuen Verarbeitungsmöglichkeiten für Daten (z. B. KI) haben zu einer deutlichen Zunahme der Bedeutung der Datenkompetenz im gesamten Maschinenbau geführt, was sich in den kommenden Jahren noch immens steigern wird. Die neuen Möglichkeiten werden den Maschinenbau nachhaltig verändern und hierfür ist Datenkompetenz erforderlich, die deutlich ausgebaut werden muss, um diese neuen Chancen wirtschaftlich nutzen zu können.“

Eine Medizinprofessorin, die zudem seit Jahrzehnten als medizinischwissenschaftliche Publizistin freiberuflich tätig ist, beobachtet: „Datenbewertung spielt eine Rolle. Wissenschaftler*innen müssen in der Lage sein, von anderen Forschern erhobene und publizierte Daten zu interpretieren und bewerten. Zu diesem Aspekt erwarte ich keine Änderung in den nächsten drei Jahren.“

6.1.2 Haltung als Kompetenzdimension

Die Bedeutung der Themen Haltung, Werte, Ethik im Zusammenhang mit Datenkompetenz nehmen die befragten Hochschulprofessor*innen sehr unterschiedlich wahr. Diejenigen mit einem Hintergrund in Statistik/Ökonometrie oder Gesellschaftswissenschaften sehen die starke Rolle der Haltung. Sie sei modularer Bestandteil in verschiedenen Studiengängen. Für den oben genannten, geplanten Master sei „Data Science“ sogar mit einem eigenen 4 SWS-Modul vorgesehen.

Der Befragte aus den Wirtschaftswissenschaften sieht das Methodenverständnis im Fokus. Er geht davon aus, dass diejenigen, die volles Methodenverständnis erlangt haben, automatisch Fragen der Ethik stellen würden.

(Wert-)Haltung und Motivation beurteilt der Professor für Raumentwicklung, ein ausgebildeter Ökonom, eher unter regulatorischen bzw. Wettbewerbsaspekten – es scheint, als halte man sich vorsorglich an ethische Standards, weil man eben müsse: „EU-Regulationen (DSGVO) determinieren den Handlungsrahmen. Bei Analysen von raumbezogenen Präferenzen und Motivlagen, die wir durch Primärerhebungen selber generieren, können Momente der Befangenheit, des Persönlichkeitsschutzes, der Vertraulichkeit dazu führen, dass Fragen zu interessierenden Sachverhalten gar nicht erst gestellt werden. Forschungsmethodische Selbstbegrenzung steht letztlich vor Regulationen, die selbstredend die Datengenerierung in der EU zunehmend beschränken. Was wir nicht erheben können, tun Forschende in den USA/UK und v. a. China viel leichter.“

Mit der Frage zur Haltung konnte der Befragte aus dem Maschinenbau nichts anfangen; er verbindet das Thema nicht mit Datenkompetenz.

Die Medizinerin ist überzeugt, dass die wissenschaftliche Datenerhebung und -Auswertung einen zugrundeliegenden Wertekanon benötige. Vor allem müsse medizinischen Forscher*innen daran gelegen sein, keine unnötigen Studien am Menschen durchzuführen, wissenschaftlich integer und korrekt zu arbeiten und die erhobenen Ergebnisse unabhängig von persönlichen Vorlieben oder Wünschen zu interpretieren.

Zwei Praktiker*innen, die im persönlichen Gespräch von der geplanten Studie erfuhren, kommentierten das Thema mit teils drastischen Schilderungen, die nochmals verdeutlichen, zu welchen Auswüchsen mangelnde Datenkompetenz in der Arbeitswelt führt:

„Ich wurde schlecht beurteilt, weil meine Prognosen von der realen Entwicklung zu stark abwichen. Dabei hatte ich gar nicht die nötigen Daten zur Verfügung. Meine Firma berät andere bei der Digitalisierung, aber wir befüllen unsere Excel-Tabellen manuell. Mein Engagement, das System zu verbessern, wird nicht zur Kenntnis genommen.“ (Leiterin Training & Development, internationale Beratungsfirma)

„Meine SAP Logins in jeder Firma waren auch immer so [aus meinen Initialen] zusammengesetzt. Stell dir vor, du bist der Arno Schmidt und musst dich jeden Tag mehrmals als ArSch1234 ins SAP einloggen.“ (Leiter Konzerncontrolling, MDAX Unternehmen)

6.1.3 Messung von Data Literacy

Datenkompetenzen werden, wenn überhaupt, nicht in Bezug auf Wissen und Fähigkeiten gemessen. Die Befragten antworten darauf wie folgt:

„Die Frage der Einstellung von Mitarbeiter*innen mit entsprechenden Kompetenzen stellt sich bei uns nicht, da in erster Linie Mitarbeiter*innen in der Verwaltung (Kompetenz nicht notwendig) und Professor*innen eingestellt werden. Bei letzterem unterliegt die Einstellung standardisierten Prozessen, in denen Datenkompetenz lediglich bei entsprechenden Denominationen eine Rolle spielt, dann allerdings extrem formal.“ (Statistik/Wirtschaft)

„Auch hier wird nur zwischen Auswendiglernenden und Verstehenden unterschieden. Es ist immer wieder erstaunlich, wie wenig der statistischen Grundbegriffe (Inferenz) aus den Einführungsveranstaltungen hängenbleiben. Interessant wäre, ob z. B. angelsächsische Universitäten hier mit mehr Pragmatismus schneller zum Kern vordringen.“ (Wirtschaftswissenschaften)

„In meinem Umfeld findet keine nennenswerte Messung von Datenkompetenz statt. Bei der Einstellung spielt dieses Thema nur dann eine Rolle, wenn die neuen Mitarbeiter*innen damit zu tun haben werden.“ (Produktentwicklung/Maschinenbau)

„Wir messen nichts; Mitarbeitende für raumanalytische Aufgaben müssen sich über methodische und inhaltliche Erfahrung ausweisen, durch Arbeitsproben. Bei Arbeitsbeginn findet Learning on the Job statt. Individuelles Coaching stellt die Lernfortschritte sicher.“ (Raumentwicklung)

„In der Medizin werde“ so die entsprechende Befragte, „Data Literacy im Sinne dieser Studie nicht gemessen“. Sie sieht allerdings ein Problem auch in dem mangelnden Bemühen, präzise deutsche Begriffe für diese Kompetenz zu finden. Der Begriff „Data Literacy“ schein ihr auch im Englischen nicht eindeutig definiert zu sein. Umso wichtiger sei es, dass sich die Arbeitsgruppe bemühen sollte, passende deutsche Begriffe zu verwenden oder zu generieren: „Ich sehe es auch in meinem Bereich Medizin, dass viele Forscher*innen in Deutschland sich nicht einmal mehr die Mühe machen, deutsche Begriffe zu finden, selbst wenn es recht einfach wäre. Und dann vermuten sie, dass der englische Begriff automatisch von Leser*innen verstanden wird. In vielen Fällen ist das sicherlich

eine Fehleinschätzung. Sprache formt das Denken. Und wie kann man denken, wenn die Begriffe fehlen?“

6.2 Ausblick auf Lernziele und Qualifikationsniveaus

Eine befragte Person sieht große Herausforderungen bei der Vermittlung von Data Literacy. Nicht zu unterschätzen sei für die Zukunft „die grundlegende Kenntnis, dass jegliche (Lern-) Prozesse ein hohes Maß an gegenseitigem Vertrauen der Beteiligten voraussetzen bzw. erst erzeugen müssen. Data Literacy wird dieser anthropologischen Konstante Rechnung tragen müssen.“

Data Literacy wird in der vorliegenden Studie als übergreifende Kompetenz aufgefasst, Lernziele müssen jedoch fachspezifisch abgeleitet werden. Es gilt deshalb in weiteren Arbeiten, in interdisziplinärer Zusammenarbeit solche Lernziele für die einzelnen Disziplinen zu entwickeln. Zudem gilt es Data-Literacy-Kompetenzniveaus festzulegen, die auch der Abgrenzung von Expert*innenniveaus (Berufsbild Data Scientist, Data Engineer und anderer angrenzender Berufe, siehe Abbildung 8) und der Abgrenzung der in den einzelnen Disziplinen anzustrebenden Niveaus dienen können. Ein Basisniveau sollte aus Sicht der Autorinnen auch in den einzelnen Fachdisziplinen hinsichtlich jeder einzelnen Kompetenz in den definierten Kompetenzfeldern vorliegen.

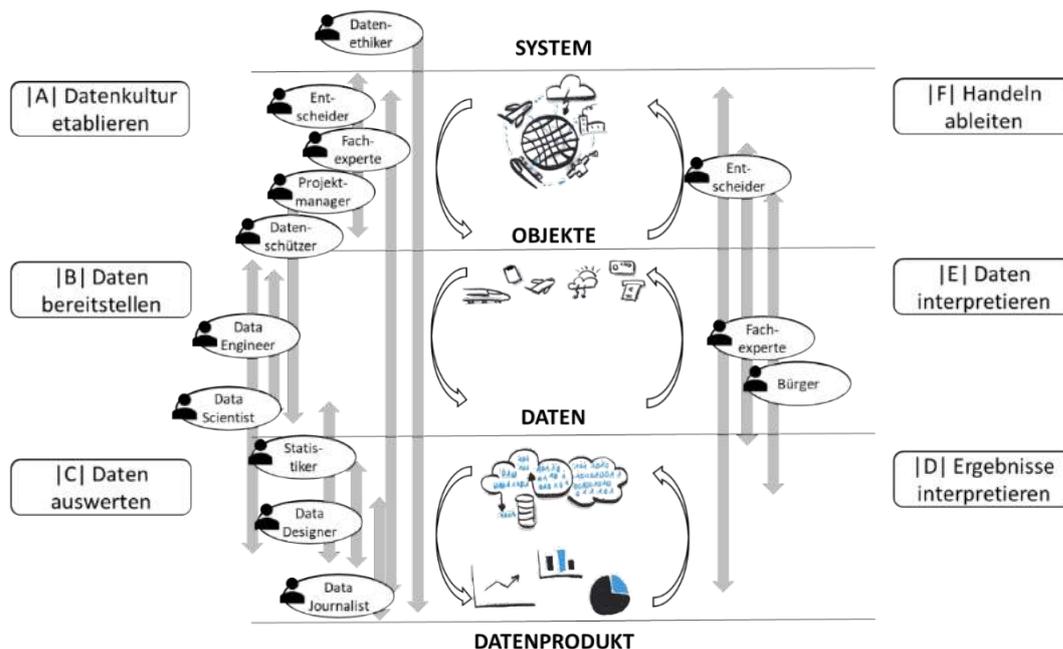


Abbildung 8: Das Data Literacy Framework und angrenzende Disziplinen und Rollen

6.3 Ausblick auf die Testentwicklung

Zur Entwicklung objektiver Tests, die Wissen und Fähigkeiten abfragen, kann auf ein umfangreiches Spektrum an Vorarbeiten zurückgegriffen werden. Die Herausforderung liegt darin, zunächst die jeweiligen fachspezifischen Lernziele und anzustrebenden Niveaus zu spezifizieren und dann die Tests sorgfältig zu validieren, um eine standardisierte Bewertung zu ermöglichen.

Für die interpretativen Testverfahren beziehungsweise die authentische Evaluation schlagen die Autorinnen der vorliegenden Studie vor, Fallstudien zu entwickeln, die sich möglichst nahe an reale

Situationen anlehnen. Eine Reihe solcher Fallstudien befindet sich im Anhang des Forschungsberichts. Zudem wurde versucht, die in den jeweiligen Fallstudien benötigten Kompetenzen im Kompetenzrahmen zu identifizieren und die Abgrenzung zwischen fachspezifischen Niveaus und Expert*innenniveaus zu ziehen. Solche Fallstudien könnten in Verbindung mit Rubriken zu einer innovativen Möglichkeit der Testung von Data Literacy führen und bei kluger Testkonzeption (z. B. durch den Aufbau von Zeitdruck) auch Wertentscheidungen erzwingen.

Eine kleine Fallstudie könnte beispielsweise folgende Aufgabenstellung umfassen, die darauf abzielt zu verdeutlichen, wie durch die Wahl einer bestimmten Darstellungsform gezielt Kontextwissen bei Rezipient*innen aktiviert wird.

6.3.1 Beispielaufgabe zu den Kompetenzen D.1 und E.1

Unter Bezugnahme auf die Allbright-Studie „Die Macht der Monokultur“ titelte das Manager-Magazin: „Der Frauenanteil in den Vorständen steigt (um 0,7 Prozentpunkte)“ („Frauen in deutschen Vorständen bleiben Exoten“, 2018). Sie erhalten folgende zusätzlichen Informationen:

- Der Frauenanteil ist um 9,75 % gestiegen.
- Der Frauenanteil betrug zuvor 7,3 %.

Frage 1	Wie groß ist der Frauenanteil in den Vorständen heute?
Frage 2	Wie viele Frauen sind heute in den Vorständen?
Antwort A	Information 1 reicht aus, um die Frage zu beantworten.
Antwort B	Information 2 reicht aus, um die Frage zu beantworten.
Antwort C	1 und 2 werden zusammen benötigt, um die Frage zu beantworten.
Antwort D	1 oder 2 alleine reichen jeweils aus, um die Frage zu beantworten.
Antwort E	1 und 2 zusammen reichen nicht aus, um die Frage zu beantworten.
Richtig sind D (Frage 1) und E (Frage 2) ² .	

Tabelle 4: Beispielaufgabe zu den Kompetenzen D.1 und E.1

6.3.2 Beispielaufgabe zusätzlich zur Kompetenz C.3

Eine weitergehende Testfrage könnte also die (falsche) Originalschlagzeile zusammen mit den Rohdaten der Studie präsentieren und fragen:

² Die Original-Schlagzeile lautete dabei fälschlicherweise: „Der Frauenanteil in den Vorständen steigt (um 0,7 Prozent).“

Antwort A	Ist die Aussage der Schlagzeile korrekt? Begründen Sie Ihre Antwort.
Antwort B	Handelt es sich Ihrer Meinung nach um eine starke oder eine schwache Veränderung? Begründen Sie Ihre Antwort.
Antwort C	(Wie) würde sich ihre Antwort zu B) verändern, wenn die Schlagzeile gelautet hätte: „Der Frauenanteil in den Vorständen steigt (um 9,75 Prozent).“
Antwort D	Wie würden Sie die Schlagzeile formulieren, um zu signalisieren, dass Sie die Frauenquote befürworten?
Antwort E	Wie würden Sie sie formulieren, um zu signalisieren, dass Sie die Frauenquote ablehnen?

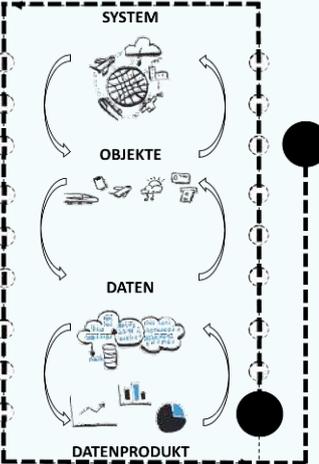
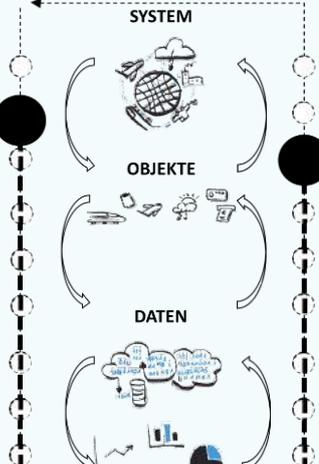
Tabelle 5: Beispielaufgabe zusätzlich zur Kompetenz C.3

Das Bemerkenswerte an der Schlagzeile ist, dass sie erst durch Kontextwissen über den derzeitigen Anteil von Frauen in Führungspositionen zur Nachricht wird: Bei fünf Prozent weiblichen Vorständen ist eine Steigerung um 0,7 % in Zusammenhang mit der andauernden Diskussion über die Quote ein „Versagen“ wahlweise der Unternehmen oder der Frauen, bei 50 % nicht der Rede wert, bei 95 % zunehmend „bedrohlich“ für die Männer. Dabei liegt hier ein handwerklicher Fehler vor, denn tatsächlich stieg der Anteil von 50/683 auf 56/697, also um 0,7 Prozentpunkte oder 9,75 %. Hätte die Schlagzeile also gelautet: „Der Frauenanteil in den Vorständen steigt (um fast zehn Prozent)“, so würde sie völlig andere Assoziationen hervorrufen. Prozente von Prozenten, die sogenannten relativen Risiken, dramatisieren Sachverhalte, weil Prozente häufig kleine Ausgangswerte bilden. In derselben Situation verharmlosen hingegen Prozentpunkte, die Differenzen von Prozentwerten bzw. absolute Risikoveränderungen, tendenziell die Veränderungen. Die Wahl der Darstellung impliziert somit bereits eine Interpretation Seitens der Rezipient*innen. Dies zu erkennen, ist ein starkes Zeichen von Data Literacy.

Anhang A: Fallstudien

Die Fallstudien im Anhang A verdeutlichen, wie das Data Literacy Framework angewandt werden kann, um die benötigten Kompetenzen für reale Fragestellungen systematisch zu identifizieren. Die Fallstudien können in der Lehre diskutiert oder auch als Übungsaufgaben/Hausarbeiten vergeben werden. Dabei lassen sich einzelne Schritte herauslösen, falls ein Fokus auf bestimmte Kompetenzen gelegt werden soll.

In der Übersicht sind die wesentlichen Kompetenzen, die für die jeweilige Fallstudie benötigt werden, nach Schwerpunkten dargestellt.

Fachgebiet	Kurzbeschreibung der Fallstudie	Einordnung in das Data Literacy Framework
<p>Medizin: Diagnostik</p>	<p>Die Fallstudie behandelt die Frage, wie die Validität des BEHAVIOUR Scores für den Einsatz als diagnostisches Instrument geprüft werden kann.</p>	
<p>Ingenieurwissenschaften: Produktionsüberwachung</p>	<p>Die Fallstudie beschäftigt sich mit der Problematik, Sensor-Fehlfunktionen aus Messdaten zu identifizieren. Dabei wird insbesondere die Frage thematisiert, was die Daten eigentlich messen.</p>	

<p>Betriebswirtschaftslehre/ Soziologie: Gender Studies</p>	<p>Die Fallstudie beschäftigt sich anhand einer publizierten Studie mit der Frage, wie einfach oder wie schwierig es ist, Argumente für oder gegen eine Frauenquote empirisch zu untermauern. Sie thematisiert besonders die Notwendigkeit der Unterscheidung zwischen Daten und der Interpretation dieser Daten.</p>	<p>Das Diagramm zeigt den Datenzyklus in einem gestrichelten Rahmen. Von oben nach unten sind die Stufen beschriftet: SYSTEM (mit einem Globus-Symbol), OBJEKTE (mit einem Smartphone-Symbol), DATEN (mit einer Cloud-Symbolik) und DATENPRODUKT (mit einem Balkendiagramm-Symbol). Die Stufen sind durch vertikale Doppelpfeile verbunden. Rechts neben dem Diagramm befinden sich zwei schwarze Kreise, die durch vertikale gestrichelte Linien mit dem Zyklus verbunden sind.</p>
<p>Verkehrswissenschaften: Mobilitätsplanung</p>	<p>Die Fallstudie beschäftigt sich mit der Frage, wie die Potenziale von Daten aus neuartigen Quellen (insbesondere App-Daten) hinsichtlich ihrer Bedeutung für die Mobilitätsplanung beurteilt werden können und ob sich daraus die Entscheidung für oder gegen die Integration von Ortsdaten – die womöglich von den Nutzer*innen negativ aufgefasst wird – unterstützen lässt.</p>	<p>Das Diagramm zeigt den Datenzyklus in einem gestrichelten Rahmen. Von oben nach unten sind die Stufen beschriftet: SYSTEM (mit einem Globus-Symbol), OBJEKTE (mit einem Smartphone-Symbol), DATEN (mit einer Cloud-Symbolik) und DATENPRODUKT (mit einem Balkendiagramm-Symbol). Die Stufen sind durch vertikale Doppelpfeile verbunden. Rechts neben dem Diagramm befinden sich zwei schwarze Kreise, die durch vertikale gestrichelte Linien mit dem Zyklus verbunden sind.</p>
<p>Psychologie: Ethik in der Forschung</p>	<p>Die Fallstudie beschäftigt sich mit einer Situation, in der die Daten einer Dissertation mit exzellenten Ergebnissen „verloren“ gegangen waren und stellt zur Diskussion, welche Kompetenzen Betreuer*innen brauchen, um solche Fälle zu vermeiden bzw. aufzudecken.</p>	<p>Das Diagramm zeigt den Datenzyklus in einem gestrichelten Rahmen. Von oben nach unten sind die Stufen beschriftet: SYSTEM (mit einem Globus-Symbol), OBJEKTE (mit einem Smartphone-Symbol), DATEN (mit einer Cloud-Symbolik) und DATENPRODUKT (mit einem Balkendiagramm-Symbol). Die Stufen sind durch vertikale Doppelpfeile verbunden. Rechts neben dem Diagramm befinden sich zwei schwarze Kreise, die durch vertikale gestrichelte Linien mit dem Zyklus verbunden sind.</p>

Tabelle 6: Übersicht der Fallstudien

A.1 Medizin: Diagnostik

A.1.1 Fragestellung

Hirnfarkte (cerebral infarction, CI) sind eine ernsthafte Komplikation bei Subarachnoidalblutungen (subarachnoid hemorrhage, SAH). Sie führen häufig zu schweren Schädigungen. BEHAVIOR ist ein neuartiger Risikoscore, der beim Einsetzen der SAH anhand von klinischen Merkmalen der Patient*innen ermittelt werden kann und dabei helfen soll, Hochrisikopatient*innen frühzeitig zu identifizieren (Jabbarli et al., 2015). Die Scorewerte liegen zwischen 0 und 11 Punkten (vgl. Abbildung 9) und Patient*innen können anhand dieser Werte in drei Gruppen (geringes, mittleres und hohes Risiko) eingeteilt werden. Die Autor*innen des Scores empfehlen eine Validierung.

<i>Score value</i>	<i>Patients developing CI (%)</i>	<i>95% confidence interval</i>
0	5.6	1.5–18.1
1	13.2	7.7–21.7
2	36.6	28.6–45.4
3	49.6	40.8–58.4
4	57.1	46.0–67.6
5	71.8	56.2–83.5
6	84.5	74.4–91.1
7	88.6	76.0–95.1
8	100.0	70.1–100.0
9	100.0	80.6–100.0
10	100.0	51.0–100.0
11	100.0	20.7–100.0

Abbreviation: CI, cerebral infarction.

Abbildung 9: Anteile der Patient*innen mit CI und zugehörige Konfidenzintervalle nach Scorewert (Jabbarli et al)

Ein*e Neurochirurg*in an einer Universitätsklinik erwägt den Einsatz des Risikoscores zur Entscheidungsunterstützung, welche therapeutischen Maßnahmen bei welchen Patient*innen ergriffen werden sollen.

A.1.2 Vorgehen der Anwender*innen und benötigte Kompetenzen

Das Vorgehen ist in der folgenden Tabelle 7 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[1]	Der Validierungsempfehlung folgend, wird entschieden, welche Merkmale zur Validierung des Scores benötigt werden ³ ,	Algorithmus verstehen und die Beschaffung der benötigten Rohdaten planen	Dekodieren	D.3
[2]	Dann wird auf die Patient*innen-Datenbank der jeweiligen Abteilung zugegriffen, ⁴	Datenquelle identifizieren und Datensatz von Patient*innen mit den benötigten Merkmalen extrahieren	Kodieren	B.1/B.2
[3]	für jede*n Patient*in ein BEHAVIOR-Score ermittelt	Algorithmus aus der Literatur auf Daten anwenden	Kodieren	B.3
[4]	und anschließend für jeden Scorewert der Anteil der Patient*innen mit CI bestimmt, vgl. Abbildung 10.	Tabelle der relativen Häufigkeiten erstellen und in einem Balkendiagramm visualisieren	Kodieren	C.1
[5]	Dabei wird festgestellt, dass der Anteil der Patient*innen mit CI an der Klinik zwar mit zunehmendem Scorewert steigt, also mit diesem positiv korreliert,	Zusammenhang zwischen Scorewert und CI-Anteil erkennen, interpretieren und beurteilen, dass dieser Zusammenhang der Erwartung entspricht	Dekodieren	D.3
[6]	jedoch fast durchgängig deutlich geringer ist als in der berichteten Stichprobe der Studie.	Differenzen der Anteile in der Grafik bzw. Häufigkeitstabelle interpretieren und beurteilen, dass eine große Abweichung vorliegt	Dekodieren	D.3
[7]	Es wird nun reflektiert, ob der Score dennoch verwendet werden kann, da es sich um eine zufällige Abweichung handelt, oder ob der Score das CI-Risiko systematisch überschätzt. ⁵	Sich bewusst machen, dass Stichproben zufällige Schwankungen aufweisen können	Dekodieren	E.1

³ Vielleicht würde der oder die Neurochirurg*in schon hier eine*n Statistiker*in beauftragen. Dann zeigt sich seine oder ihre Data Literacy darin, dass er oder sie nicht nur die Berechnung des Scores beauftragt („berechne mir, welche Patient*innen zur Hochrisikogruppe gehören“), sondern dass er die Validierung beauftragt („prüfe, ob diese Patient*innen wirklich Hochrisikopatienten sind, wenn der Score das sagt“). Es wäre die grundlegendste Stufe von Data Literacy, dass man einen solchen Algorithmus kritisch hinterfragt.

⁴ Dieser Schritt wird in anderen Organisationen ggf. von einer*m eigenen Datenmanager*in durchgeführt. Die Aufgabe des oder der Neurochirurg*in ist dann die Spezifikation von Anforderungen und die Prüfung des gelieferten Datenexports.

⁵ Hier könnte man eine weitere Stufe von Data Literacy abgrenzen, d.h. auch hier könnten Expert*innen eingeschaltet werden. Bis hierhin ist alles eine deskriptive Analyse, die man auch mit Excel oder per Hand durchführen kann. Der Fisher-Test gehört zwar eigentlich in Statistik-Kursen für Mediziner*innen zum üblichen Lernstoff. Aber die Anwendung in realen Situationen wird selten geübt.

[8]	Es wird erkannt, dass diese Fragestellung einen Signifikanztest zum Vergleich der Anteilswerte in zwei zufälligen Stichproben (Patient*innenstichprobe der Studie und Patient*innenstichprobe der Klinik) erfordert,	Medizinische Fragestellung („Überschätzt der Score das Risiko systematisch?“) in eine statistische Fragestellung („Unterscheiden sich die Anteile signifikant?“) übersetzen	Codieren	C.1
-----	--	---	----------	-----

Tabelle 7: Vorgehen der Anwender*innen und benötigte Kompetenzen [Fallstudie 1]

Abbildung 10: Vergleich der Patient*innenstichproben aus der Studie und der Datenbank

A.1.3 Vorgehen der Expert*innen und benötigte Kompetenzen

Das Vorgehen der Statistiker*innen ist in der folgenden Tabelle 8 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[9]	Statistikexpert*innen bestätigen die Einschätzung der Neurochirurg*in hinsichtlich des benötigten Testverfahrens.	Abstrakte Testsituation erkennen und bewerten, geeigneten Test auswählen	Kodieren	C.1
[10]	Es wird gewusst, dass entsprechend für die Anzahl von unabhängigen Ereignissen (hier: Patient*in erleidet CI) eine Binomialverteilung angenommen werden muss.	Voraussetzungen des Tests prüfen	Kodieren	C.1
[11]	Den publizierten Angaben wird entnommen, dass insgesamt 632 Patient*innen analysiert wurden, darunter 320 CI-Fälle. 596 Patient*innen wiesen mindestens einen Risikofaktor auf (d.h. 36 hatten einen Scorewert von 0); eine	Publikation systematisch nach den benötigten Angaben durchsuchen	Dekodieren	D.1

[11]	Person hatte einen Scorewert von 11.			
[12]	Aus diesen rekonstruierten Rohwerten für zwei Gruppen wird jeweils das Konfidenzintervall – unter Annahme einer Binomialverteilung – berechnet	Benötigte Vergleichsgrößen berechnen	Kodieren	C.1
[13]	und festgestellt, dass es mit den publizierten Angaben in Abbildung 10: Vergleich der Patient*innenstichproben aus der Studie und der Datenbank übereinstimmt.	Publizierte Ergebnisse in Bezug auf die Berechnung interpretieren	Dekodieren	D.3
[14]	Durch eine Art „reverse engineering“, d.h. ein iteriertes Verteilen der verbleibenden 595 Patient*innen und 317 CI-Fälle auf die restlichen Scoreklassen 1 bis 10 und Berechnen der Anteilswerte bzw. Konfidenzintervalle, gelingt es Statistik-expert*innen, die Fallzahlen zu rekonstruieren, vgl. Tabelle 9	Bedeutung der publizierten Kenngrößen entschlüsseln und auf die Originaldaten rückschließen	Dekodieren	E.1
[15]	Mit diesen Angaben kann dann der Test nach Fisher durchgeführt, vgl. Tabelle 10	Statistischen Test durchführen	Dekodieren	C.1
[16]	und die Ergebnisse interpretiert werden.	Testergebnisse interpretieren	Dekodieren	D.1

Tabelle 8: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 1)

Score	Patient*innen	Patienten mit CI	Patient*innen mit CI (Anteil)
0	36	2	0,056
1	91	12	0,132
2	123	45	0,366
3	121	60	0,496
4	77	44	0,571
5	39	28	0,718
6	71	60	0,845
7	44	39	0,886
8	9	9	1,000

Tabelle 9: Rohwerte aus Jabbarli et al. (rekonstruiert)

A.1.4 Ergebnis

Das Testergebnis in Tabelle 10 zeigt, dass in sechs von elf Scoregruppen die Nullhypothese gleicher CI-Anteile in den Stichproben zum Niveau $\alpha = 0.05$ verworfen werden muss⁶. Dabei treten signifikante Abweichungen stets in eine Richtung ($p_2 < p_1$) auf. Die Wahrscheinlichkeit, eine solche Situation zu beobachten, wenn keine systematische Verzerrung vorliegt, liegt bei $p < 0.001$, d.h. es ist nicht durch Zufall zu erklären, dass so viele signifikante Abweichungen in dieselbe Richtung auftreten. Es ist somit davon auszugehen, dass der BEHAVIOR-Score in der vorliegenden Stichprobe das CI-Risiko systematisch überschätzt.

Diese Einschätzung wird dem oder der Neurochirurg*in mitgeteilt. Jene*r entscheidet daraufhin, die Klassifikation von Patient*innen in solche mit geringem, mittlerem und hohem Risiko nicht aus der Studie zu übernehmen, sondern anzupassen.⁷

⁶ Bei einseitigem Testen ($H_0: p_1 \geq p_2$) treten sieben signifikante Abweichungen auf.

⁷ Hierfür konsultiert er oder sie erneut Expert*innen; auf die Beschreibung der weiteren Schritte verzichten wir.

Scorewert	CI-Anteil (Jabbarli et al.)	CI-Anteil (Klinik)	Signifikanz (p-Wert)
0	0,056	0,064	1,000
1	0,132	0,160	0,683
2	0,366	0,190	0,026*
3	0,496	0,298	0,002**
4	0,571	0,315	0,141
5	0,718	0,348	0,001**
6	0,845	0,439	0,000***
7	0,886	0,447	0,000***
8	1,000	0,615	0,054
9	1,000	0,833	0,027*
10	1,000	1,000	1,000
11	1,000	keine Angabe	keine Angabe

Tabelle 10: Fisher-Test (zweiseitig) auf Gleichheit der CI%-Anteile in den beiden Stichproben

A.2 Ingenieurswissenschaften: Produktionsüberwachung

A.2.1 Fragestellung

Während der Produktion von Karosseriebauteilen werden die Eigenschaften von Halbzeugen (einfachste Bauteile aus einem einzigen Material, hier Blech) laufend mit Hilfe von Sensoren überwacht. Dabei werden die Messwerte laufend gespeichert. Nicht nur die Halbzeuge, sondern auch die Sensoren selbst können jedoch fehlerhaft sein. Im vorliegenden Fall werden aus sogenannten Coils (Bandstahl- bzw. Aluminiumrollen) die Karosserieteile ausgeschnitten. Mit Sensoren werden Materialeigenschaften wie Blechdicke, Schmierstoffmenge, Rauigkeit und mechanische Eigenschaften der Schmierstoffe erfasst. Dabei können verschiedene Messtechnologien, z.B. optische Sensoren oder magnetinduktive Technologien (IMPOC) eingesetzt werden, die unterschiedliche Daten liefern.

Ein*e Produktionsleiter*in schlägt vor, mit Hilfe geeigneter Algorithmen mögliche Fehlfunktionen der Sensoren zu detektieren. Hierfür müssen mögliche statistische Verfahren bzw. Algorithmen zur Erkennung solcher Fehlfunktionen identifiziert, bewertet und schließlich probeweise implementiert werden, um aus den Ergebnissen Rückschlüsse über die Möglichkeiten und Grenzen einer datenbasierten Produktionsüberwachung ziehen zu können. Der oder die Produktionsleiter*in beauftragt eine*n Werkstudent*in der Ingenieurswissenschaften mit der Aufgabe, eine Empfehlung hinsichtlich des weiteren Vorgehens zu erarbeiten. Für den Fall, dass sich eine Umsetzung lohnt, soll ein Data Scientist geeignete Algorithmen testweise implementieren.

A.2.2 Vorgehen des oder der Anwender*in und benötigte Kompetenzen

Das Vorgehen des oder der Werkstudent*in ist in der folgenden Tabelle 11 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[1]	Zunächst muss das Problem sowie eine korrespondierende Fragestellung formuliert werden: Können Zeitpunkte, zu denen Sensoren defekt sind, anhand ihrer Messwerte ermittelt werden?	Aufgabenstellung abstrahieren, eine Vorstellung des datengenerierenden Prozesses und seiner Elemente entwickeln	Kodieren	A.2
[2]	Es wird mit Anwender*innen aus verschiedenen Fachbereichen Rücksprache gehalten und ergänzend eine Internetrecherche durchgeführt, um Analogien aus anderen Industriezweigen zu finden.	Fach-expert*innen mit benötigter Expertise identifizieren und Informationen zur Planung des Projekts beschaffen	Kodieren	A.3
[3]	Charakterisierung möglicher, typischer Datenstrukturen.	Prozesscharakteristika in Daten abbilden und Daten beschreiben	Kodieren	B.1

[4]	Definition von Bewertungskriterien, um die Übertragbarkeit der Ergebnisse bezüglich Relevanz und Nutzbarkeit zu beurteilen	Schwachstellen der Analyse und möglichen Fehlschlüsse antizipieren	Dekodieren	D.1/E.3
[5]	Ableitung geeigneter statistischer Modelle für die erwarteten Datenstrukturen ⁸ .	Voraussetzungen der Analyseverfahren kennen und prüfen	Kodieren	C.1
[6]	Es wird eine Suchstrategie sowie ein Rechercheplan aufgestellt ⁹ ,	Überlegen, wo/wie die Informationen gefunden werden können	Dekodieren	E.2
[7]	eine Literaturrecherche durchgeführt, die zum Ziel hat, übertragbare Datenanalysen zu identifizieren und deren Stärken bzw. Schwächen zu verstehen	Schlagwörter identifizieren und Internet bzw. geeignete Datenbanken systematisch durchsuchen	Dekodieren	E.2
[8]	und die Literatur evaluiert (insbesondere Anwendungsfälle, Präzision der Algorithmen, Darstellung der Limitationen).	Dargestellte Analysen und Daten hinsichtlich eines möglichen Transfers interpretieren	Dekodieren	D.3/E.3
[9]	Ableitung der Schlussfolgerung, dass mehrere Algorithmen geeignet sein könnten, um die Produktion datenbasiert zu überwachen.	Ableiten, welche Entscheidung getroffen werden soll	Dekodieren	F.1

Tabelle 11: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 2)

⁸ Hier oder bereits im vorangehenden Schritt wird vermutlich der oder die Data Scientist konsultiert.

⁹ Hier wird deutlich, dass auch Kompetenzen aus dem Bereich Information Literacy benötigt werden.

A.2.3 Vorgehen der Expert*innen und benötigte Kompetenzen

Der oder die Werkstudent*in übergibt die Literaturstudie nun an den oder die Data Scientist. Dessen bzw. deren Vorgehen ist in der folgenden Tabelle 12 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[10]	Der Data Scientist entscheidet sich, Messwerte von Sensoren für drei Materialeigenschaften – die Banddicke, die Schmierstoffmenge und den IMPOC Wert von Stahl oder Aluminiumbauteilen – aus verschiedenen Anlagen und Programmen zu untersuchen, um informationsreiche Daten zu erhalten.	Stärken und Schwächen der Messmethoden abwägen und geeignete Messwerte auswählen	Kodieren	B.1
[11]	Es wird entschieden, welche Algorithmen implementiert werden sollen: Support Vector Machines (unsupervised, multivariat), Kalman Filter (kombinierbar mit weiteren Methoden, multivariat) und zeitreihenbasierte Anomalie-Detektion (univariat, einfach zu implementieren). Dabei wird der erwartete Nutzen, aber auch der jeweilige Aufwand der Analyse berücksichtigt.	Analyseverfahren nach verschiedenen Kriterien (Kosten und Nutzen der jeweiligen Implementierung) bewerten und auswählen	Kodieren	C.1
[12]	Erstellung eines Implementierungs-/Testkonzepts.	Datenprojekt planen	Kodieren	A.3
[13]	Es wird antizipiert, wie zufällige Variationen in den Daten von systematischen Fehlern unterschieden werden können, welche Muster auf Fehler in den Sensoren hinweisen und wie diese von „echten“ Materialfehlern unterschieden werden können. Zudem wird die Tatsache reflektiert, dass dies teilweise subjektive Wertungen beinhaltet.	Mögliche Kennwerte, die aus den Daten berechnet werden können (z.B. Quantile, Korrelationen) hinsichtlich ihrer Aussagekraft bezüglich der Problemstellung abwägen	Dekodieren	D.1/E.1

[14]	Zudem werden Informationen bezüglich möglicher Messfehler eingeholt und überlegt, wie diese Unsicherheit in den Ergebnissen berücksichtigt werden kann (z.B. durch eine Erweiterung des Korridors, welche Werte als „normal“ anzusehen sind).	Fehlerquellen kennen und deren mögliche Auswirkungen abwägen (Reliabilität und Validität der Messung)	Dekodieren	E.2
[15]	Beschaffung von Testdaten	Zugreifen auf die Datenquelle	Kodieren	B.2
[16]	Erstellung einer bzw. mehrere Basistabellen für die Analysen.	Benötigte Datenstruktur planen und Daten darin integrieren	Kodieren	B.2
[17]	Aufbereitung der Daten, z.B. indem Ausreißer identifiziert sowie markiert und indem er dimensionsreduzierende Verfahren (Hauptkomponentenanalyse) angewandt werden, um die Information in den Daten zu komprimieren.	Daten verifizieren und transformieren in dem Bewusstsein, welche Informationen dadurch sichtbar werden und welche verloren gehen („Signal vs. Noise“)	Kodieren	B.3
[18]	Im Anschluss werden dann die ausgewählten Algorithmen implementiert und die Daten dadurch analysiert	Analyseverfahren programmieren und anwenden	Kodieren	C.1
[19]	Visualisierung des Ergebnisses (vgl. Abbildung 11),	Passende Visualisierungsmethoden	Kodieren	C.2
[20]	Es wird geschlussfolgert, dass (1.) die Algorithmen bzw. statistischen Modelle gut geeignet sind, um Anomalien zu erkennen;	Analysen interpretieren hinsichtlich ihrer Aussagekraft bezüglich der Fragestellung	Dekodieren	D.3
[21]	und (2.) deutlich weniger Messpunkte benötigt werden, um die Produktion zu überwachen, weil die Messungen redundant sind.	Bewerten, wie gut die Daten geeignet sind, um die Fragestellung zu beantworten	Dekodieren	E.1/E.3
[22]	Zusammenfassung der Ergebnisse in einem adressatengerechten Abschlussbericht	Ergebnisse für Nicht-Expert*innen verständlich formulieren	Kodieren	C.3
[23]	Formulierung von Empfehlungen für die zukünftige Anwendung der	Entscheidung treffen, basierend auf den Daten	Dekodieren	F.1

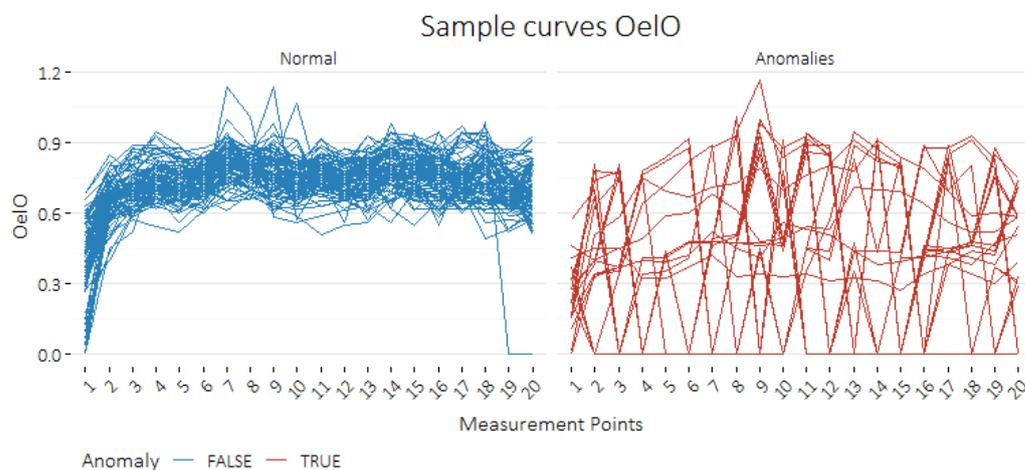
[23]

Methodik.

Tabelle 12: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 2)

A.2.4 Ergebnis

In den Daten lagen keine Informationen zu tatsächlichen Sensordefekten vor, aber eine Häufung von Anomalien zu bestimmten Zeitpunkten kann als Indiz für eine Sensorfehlfunktion interpretiert werden. Das gilt insbesondere, wenn diese an derselben Maschine über mehrere Coils oder Materialien hinweg besteht. Ein Beispiel zeigt Abbildung 12, wo bei transformierten Daten (Reduktion auf die erste Hauptkomponente, d.h. die wichtigste Dimension in den Messdaten) sehr unregelmäßige Messungen der Schmierstoffmenge bei aufeinanderfolgenden Coils beobachtet werden konnten.



Program_Machineld: 46_9

Abbildung 11: Visualisierung von Messzeitpunkten und Anomalien bei transformierten Daten

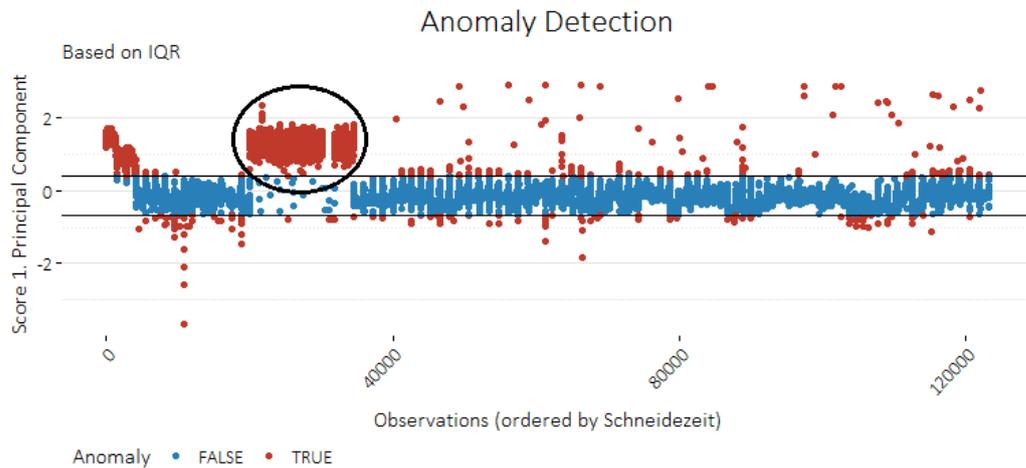


Abbildung 12: Visualisierung von Messzeitreihen und Anomalien bei Rohdaten

Es zeigt sich, dass insbesondere die Kombination der Algorithmen einen Mehrwert liefert, je nach interessierender Materialeigenschaft.

- Die drei Messungen der Banddicke korrelieren stark und da es sich um unabhängige Sensoren handelt, kann diese Information genutzt werden, um defekte Sensoren mit linearen Regressionsmodellen zu identifizieren.
- Eine Dimensionsreduktion zeigt interessante Korrelationsmuster zwischen benachbarten Messungen der Schmierstoffmenge und auch zwischen Ober- und Unterseitenmessungen. Diese Muster sind eine Art „Fingerabdruck“ des Materials.
- Mit einem Kalman-Filter können plötzliche Sprünge in Mittelwert oder Varianz des Impoc Wertes sehr gut entdeckt werden.

A.3 Betriebswirtschaftslehre/Soziologie: Gender Studies

A.3.1 Fragestellung

Im Sommer 2014, als die Einführung der (inzwischen für die Aufsichtsräte börsennotierter und voll mitbestimmter Unternehmen gesetzlich vorgegebenen) Gender-Quote in Deutschland intensiv diskutiert wurde, veröffentlichte eine Unternehmensberatung eine Pressemeldung mit dem Titel: „Rückschlag bei Frauenquote in DAX-Vorständen“. Dort war zu lesen: „Da war dann offensichtlich manchmal das Geschlecht wichtiger als die beste fachliche Eignung“, vermutet Co-Studienautor Christoph Lesch, Director bei Simon Kucher. Seine These sieht er von der Tatsache gestützt, dass die durchschnittliche Amtszeit der ausgeschiedenen weiblichen Vorstände bei nur knapp drei Jahren liegt, während sie bei den männlichen Kollegen mit über acht Jahren fast dreimal so hoch ist“ (Müller-Vogg, 2014).

Eine Reihe von Medien griff das Thema auf, etwa die Wirtschaftswoche oder die Süddeutsche Zeitung: „Neueste Studien zeigen, dass weibliche Vorstände durchschnittlich nach etwa drei Jahren aus ihrem Amt scheidet, während Männer acht Jahre verweilen - und damit fast drei Mal so lang. Ein mit Einzelfällen nicht erklärbares Muster“ (Sattelberger, 2014). „Wegen des öffentlichen Drucks versuchen Unternehmen zunehmend, Frauen in sichtbare Top-Positionen zu bringen. Oft sind das Quereinsteigerinnen, die schnell Karriere gemacht haben - nicht immer geht das gut“ (Büschemann & Busse, 2014). Laut Ann-Christin Achleitner würden Frauen „häufig eilig von außen ins Unternehmen geholt, um bestimmte Quoten zu erreichen.“

Eine NGO, die sich für die Förderung von Frauen in Vorstands- und Aufsichtsratspositionen einsetzt, befürchtet infolge dieser Veröffentlichung zusätzliche Widerstände gegen ihr Engagement. Deren Vorstandsmitglieder beauftragen deshalb eine*n Werkstudent*in der Betriebswirtschaftslehre, die Ergebnisse kritisch zu hinterfragen. Weil bekannt ist, dass Frauen häufiger als Männer das Personalressort besetzen, schlägt die oder der Wertstudent*in vor, dies gesondert zu betrachten.

A.3.2 Vorgehen der Anwender*innen und benötigte Kompetenzen

Das Vorgehen des oder der Werkstudent*in ist in der folgenden Tabelle 13 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[1]	Zunächst wird im Internet recherchiert und festgestellt, dass in den Jahren 2000 bis 2006 keine Frau in einem DAX-Vorstand vertreten war. Erst im Jahr 2007 wurde Bettina von Oesterreich in den Vorstand der Hypo Real Estate berufen und war dort für 2 Jahre im Amt.	Informationsquellen identifizieren und Informationen beschaffen.	Dekodieren	E.2
[2]	Es wird errechnet, dass – selbst wenn alle seitdem in DAX-Vorstände berufenen Frauen bis	Rückschlüsse aus einer statistischen Kennzahl (Mittelwert) auf Daten	Dekodieren	E.1

[2]	zum Zeitpunkt seiner Analyse im Amt geblieben wären – deren durchschnittliche Verweildauer weniger als 7 Jahre betragen muss.	ziehen und Widersprüche aufdecken		
[3]	Schlussfolgerung, dass die in der Studie berechneten Verweildauern für Frauen und Männer nicht miteinander vergleichbar sind	Schlussfolgerungen aus Daten kritisch hinterfragen und Aussagekraft der Daten beurteilen	Dekodieren	E.3/D.3
[4]	und dass sich dementsprechend ein Vergleich auf die seit 2007 berufenen Vorstände beschränken sollte.	Geeignete Daten und deren Analyse vorschlagen	Kodieren	A.1
[5]	Reflexion statistischen Grundlagenwissens resultiert in Vergewisserung, dass eine eventuelle Korrelation zwischen Geschlecht und Verweildauer keine Kausalität bedeutet.	Grundlegendes Verständnis der Aussagekraft einer Korrelation	Dekodieren	D.1
[6]	Es wird erkannt, dass neben dem Datum von Amtsantritt und -ende und dem Geschlecht noch Informationen über Alter, Qualifikation, Quereinstieg und Tätigkeit sinnvoll sind, um Fehlschlüsse zu vermeiden.	Wissen über mögliche Zusammenhänge in benötigte Informationen übersetzen	Kodieren	A.2
[7]	Es wird entschieden, die Qualifikation über einen MBA bzw. eine Promotion abzubilden und die Tätigkeit über das Vorstandsressort, da diese Daten öffentlich verfügbar sind.	Geeignete Operationalisierungen von Eigenschaften erkennen, auch unter dem Aspekt einer effizienten Beschaffung	Kodieren	B.1.1
[8]	Vergewisserung, dass es bei der geplanten Analyse publizierter Daten keine datenschutzrechtlichen Bedenken gibt.	Wissen, was personenbezogene Daten sind, dass sie besonderen Schutz genießen, und prüfen, ob die Analyse möglich ist	Kodieren	B.1.2
[9]	Recherche bezüglich der Zusammensetzung des DAX seit 2007 und Beschaffung sämtlicher Geschäftsberichte, um Daten über die Vorstände zu erhalten.	Datenquelle finden und Internetrecherche durchführen	Kodieren	B.2.1

[10]	Anlegen einer Tabelle mit den benötigten Variablen sowie sachgerechte Speicherung der Daten aus den Geschäftsberichten.	Daten aus verschiedenen Quellen kombinieren und in einheitliche Analysetabelle integrieren	Kodieren	B.2.2
[11]	Es wird erkannt, dass nicht alle Informationen (z.B. Werdegang) in den Berichten enthalten sind	Fehler und Lücken in den Daten erkennen	Kodieren	B.3.1
[12]	Fehlende Daten werden durch weitere Recherchen zu den jeweiligen Personen ergänzt.	Weitere Daten beschaffen, um Fehler und Lücken zu beheben	Kodieren	B.2.1/B.3.1
[13]	Berechnung der Verweildauer aus dem Eintritts- und Austrittsdatum jeder Person	Daten so kombinieren, dass eine neue Information entsteht	Kodieren	B.3.2
[14]	Zusätzliche Berechnung des Frauenanteils pro Jahr	Daten aggregieren, um Aussagen über eine andere Betrachtungsebene/andere Objekte (Unternehmen bzw. System statt Personen) zu erhalten	Kodieren	B.3.3
[15]	Berechnung der mittleren Verweildauer im Vorstand für noch aktive bzw. ausgeschiedene Männer und Frauen	Daten gruppieren und gruppenweise analysieren	Kodieren	C.1
[16]	Grafische Darstellung der Ergebnisse mittels Boxplots (Abbildung 13)	Geeignete Visualisierung für metrische Zielgröße auswählen und umsetzen	Kodieren	C.2
[17]	Um ein Verständnis möglicher Zusammenhänge zu erhalten, werden Kreuztabellen der relativen Häufigkeiten für die Merkmale	Verteilungen durch eine geeignete Analyse vergleichbar machen	Kodieren	C.1
[17]	Geschlecht (m/w), Quereinstieg ins Unternehmen, noch aktiv, bis/ab 40, MPB/Promotion, sowie Personalressort (jeweils ja/nein) berechnet			
[18]	Grafische Darstellung der Ergebnisse in Form von Balkendiagrammen (Abbildung 14).	Geeignete Visualisierung für zwei kategoriale Merkmale auswählen und umsetzen	Kodieren	C.2

[19]	Hypothesengeleitete Interpretation der Daten und Schlussfolgerung, dass Geschlecht kein kausaler Einflussfaktor für Verweildauer von Führungskräften ist.	Visuelle Analysen interpretieren	Dekodieren	D.2
[20]	Erkenntnis, dass deskriptive Analysen keine Aussagen über Kausalität erlauben.	Grenzen der Aussagekraft deskriptiver Analysen erkennen	Dekodieren	D.1
[21]	Es wird vorgeschlagen, weitere Analysen durch Fachexpert*innen durchführen zu lassen	Grenzen der eigenen Kompetenz erkennen und Expert*innenrat einholen	Kodieren	A.3

Tabelle 13: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 3)

A.3.3 Vorgehen der Expert*innen und benötigte Kompetenzen

Das Vorgehen der Statistiker*innen ist in der folgenden Tabelle systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[22]	Statistikexpert*innen erkennen, dass Überlebensdauern aus zensierten Daten berechnet werden sollen (d.h. solchen, bei denen teilweise der Zeitpunkt des „Versterbens“ nicht bekannt ist)	Fragestellung in ein statistisches Analyseproblem übersetzen	Codieren	A.2
[23]	Und entscheiden, dass Survival-Analysen (Kaplan-Meier-Schätzung, Log-Rank-Test, Cox-Regression) hierfür geeignet sind	Geeignetes Analyseverfahren auswählen	Codieren	C.1
[24]	Die Daten werden in ein sachadäquates Format transformiert, so dass zu jedem Zeitpunkt die Zahl der noch aktiven und die Zahl der ausgeschiedenen Vorstände mit Zusatzmerkmalen (Geschlecht, Quereinstieg, etc.) abgebildet ist.	Daten so umstrukturieren, dass das Analyseverfahren eingesetzt werden kann	Codieren	B.3.2
[25]	Es wird die Überlebenskurve in einem einfachen Modell berechnet, in dem nur das Geschlecht berücksichtigt	Erkennen, dass zunächst ein Zusammenhang zwischen Verweildauer und Ge-	Codieren	C.1/C2

	wird (Abbildung 15)	schlecht geprüft werden muss (denn wenn dieser nicht signifikant ist, braucht man nicht tiefer einzusteigen)		
[26]	Es wird ein signifikanter Geschlechtsunterschied erkannt.	Analyseergebnis interpretieren	Decodieren	D.1/D.2
[27]	Anschließend wird das Modell unter Einbeziehung der signifikanten Kovariablen „Personalressort“ und „Quereinstieg“ berechnet	Erkennen, dass eine vertiefte Analyse sinnvoll ist, um mögliche Verzerrungen durch andere Einflüsse auszuschließen	Codieren	C.1/C.2
[28]	und festgestellt, dass der signifikante Geschlechtsunterschied verschwindet (Abbildung 16)	Analyseergebnis interpretieren	Decodieren	D.1/D.2
[29]	Es werden die Ergebnisse interpretiert und dem Vorstand der NGO vorgeschlagen, diese z.B. in einer geeigneten Pressemitteilung zu kommunizieren.	Ergebnis kommunizieren und Handeln empfehlen	Decodieren	E.1
[30]	Schließlich wird dabei geholfen, einen entsprechenden Vortrag sowie einen Gastbeitrag für eine Wirtschaftszeitung zu verfassen.	Verbalisieren der Daten	Codieren	C.3

Tabelle 14: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 4)

A.3.4 Ergebnis

Die Unterschiede in der Verweildauer nivellieren sich, wenn nach aktivem Vorstandsamt und Geschlecht unterschieden wird, wie die folgende Abbildung 13 zeigt.

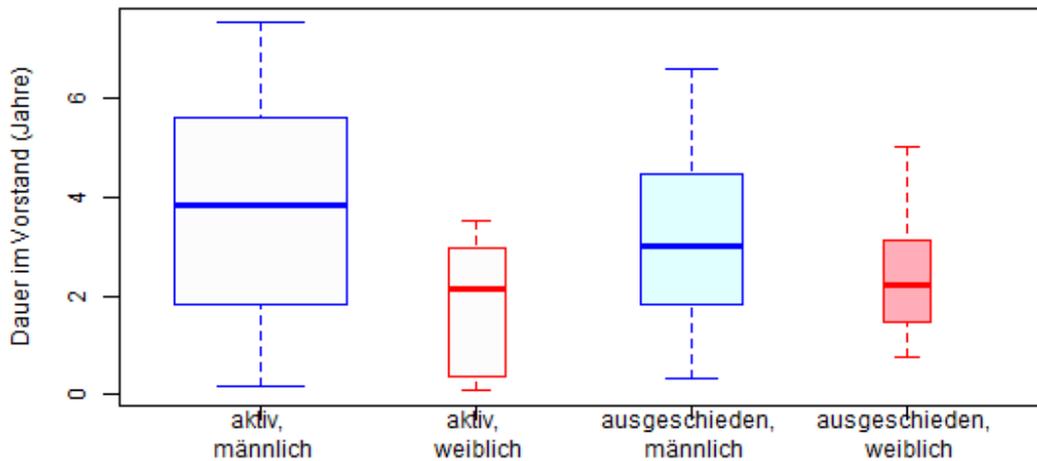


Abbildung 13: Boxplots der Verweildauer im Vorstand; ab 2007 im DAX-30 gelistete Unternehmen; neu berufene Vorstände

Der oder die Werkstudent*in formuliert aufgrund seiner bzw. ihrer deskriptiven Analysen in Abbildung 14 folgende Hypothesen:

- **Frauen sind häufiger Quereinsteigerinnen.** Es wird vermutet, dass es problematisch sein könnte, wenn Quereinsteigerinnen sich im Unternehmen nicht auskennen und wenn sie dort keine Verbündeten („Male Allies“) haben oder vielmehr sogar „Male Enemies“, die den Vorstandsposten auch gerne gehabt hätten.
- **Frauen besetzen häufiger das Personalressort.** Es wird vermutet, dass Vorstände im Personalressort besonders starke („Male“) Allies benötigen, gut vernetzt sein und mit der Kultur des Unternehmens besonders vertraut sein müssen, weil aus der Organisationsforschung bekannt ist, dass der „Cultural Fit“ für den Erfolg von Führungspersonen besonders wichtig ist. Zudem wird angenommen, dass Frauen durch geschlechtstypische Persönlichkeitseigenschaften („Soft Skills“) dafür besser geeignet sein könnten.
- **Frauen wechseln häufiger extern ins Personalressort.** Die Analysen zeigen, dass die relative Chance, als Quereinsteiger*in ins Personalressort zu wechseln, bei Frauen neunmal so hoch ist wie bei Männern.
- **Quereinsteiger*innen verbleiben seltener im Vorstand.** Auch dies zeigen die Berechnungen. Es besteht nämlich ein statistischer Zusammenhang zwischen der Erfahrung im Unternehmen und der Verweildauer im Vorstand. Von außerhalb berufene Vorstandsmitglieder scheiden besonders im Personalressort rascher wieder aus.
- **Alter und Qualifikation besitzen keinen Einfluss auf die Verweildauer.**

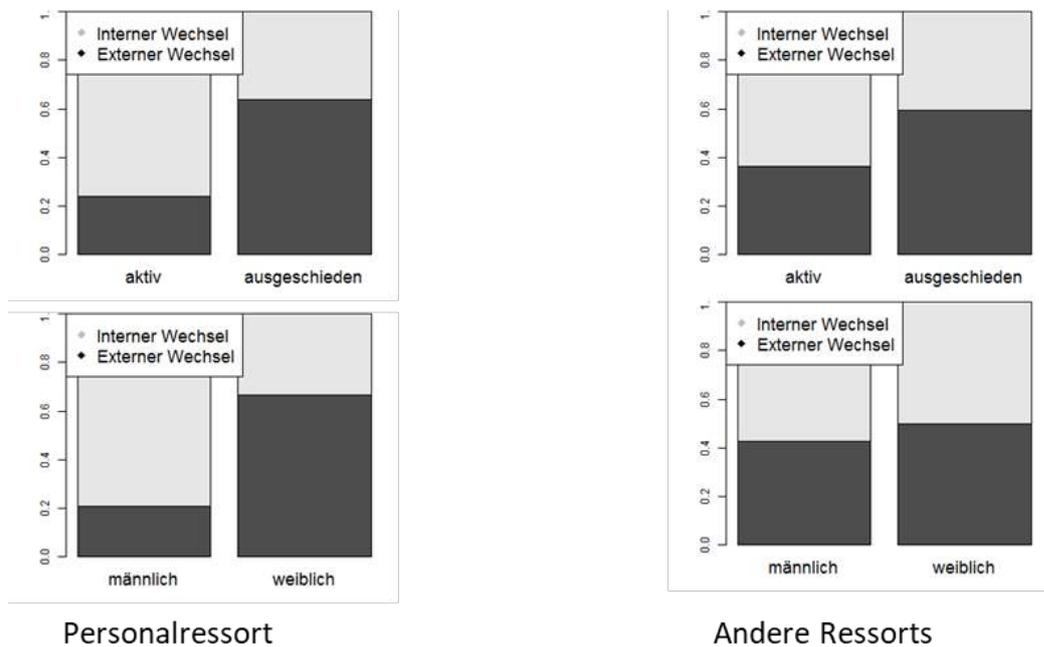


Abbildung 14: Kreuztabellen für verschiedene Merkmale von Vorstandsmitgliedern

Bei einer Survivalanalyse rein nach Geschlecht (Abbildung 15) zeigt sich, dass die insgesamt 24 Frauen signifikant kürzer im Amt verblieben sind als die 209 Männer, was statistisch gesehen ein systematisches Muster in den Überlebenskurven (durchgängige Linien) darstellt. Aufgrund der geringen Fallzahl bei den Frauen ist die Unsicherheit jedoch hoch, wie den breiten Konfidenzbändern (gestrichelte Linien) zu entnehmen ist.

Ein Modell mit den weiteren potenziellen Einflussgrößen erlaubt die Betrachtungsweise: „Was wäre, wenn Männer und Frauen gleiche Voraussetzungen hätten?“ Es bereinigt die Überlebenskurven um die Faktoren „Personalressort“ und „Quereinstieg“ sowie deren Wechselwirkung.

Das Modell in Abbildung 16 zeigt, dass die Kombination „Personalressort“ und „Quereinstieg“ für Frauen wie für Männer gleichermaßen „tödlich“ ist. Der Unterschied der Überlebensdauer zwischen Männern und Frauen ist nach der Bereinigung nicht signifikant, statistisch gesehen also Zufall. Das heißt, Frauen sind – gemessen an ihrer „Überlebensfähigkeit“ – keine schlechteren Vorstandsmitglieder als Männer, sie sind aber auch nicht aufgrund ihres Geschlechts für das Personalressort besser geeignet.

Das Modell bestätigt somit die Hypothesen und lässt den Schluss zu, dass die Behauptung „Quoten-Frauen sind schlechter geeignet“ falsch ist, sondern dass vielmehr Frauen und Männer sich bei der Übernahme einer Vorstandsposition in kritischen Faktoren unterscheiden

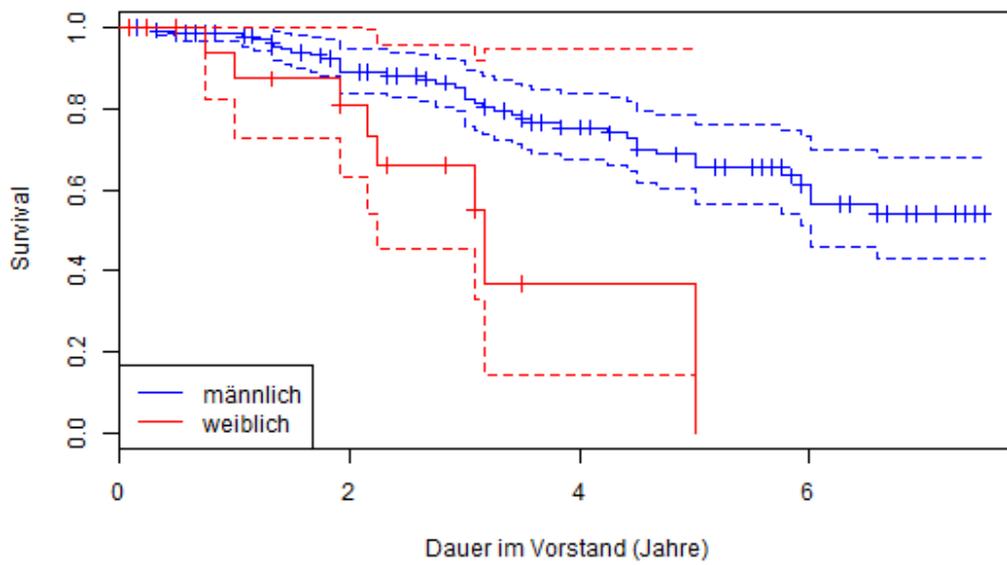


Abbildung 15: Analyse der Überlebenszeit, nur nach Geschlecht

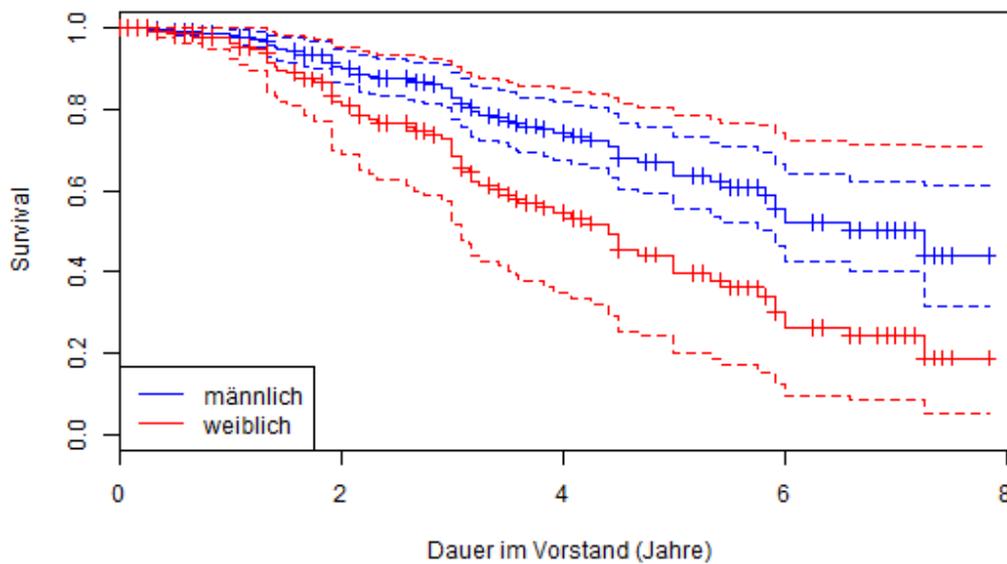


Abbildung 16: Analyse der Überlebenszeit, bereinigt um kritische Faktoren

A.4 Verkehrswissenschaften: Mobilitätsplanung

A.4.1 Fragestellung

Datenbasierte Verkehrsplanung und Fahrgaststeuerung bietet eine Vielzahl an Vorteilen für Fahrgäste und Verkehrsverbund. Fahrgäste sollen zufriedener sein, indem z.B. Wartezeiten verringert werden, der Überfüllung entgegengesteuert wird, Routenvorschläge optimiert werden. Der Verkehrsverbund wird durch das Angebot der datenbasierten Fahrgaststeuerung attraktiver, die Kundenzufriedenheit steigt, der Verbund erhält ein moderneres, innovativeres Image und Digitalisierungskompetenzen werden aufgebaut.

Ein*e Manager*in eines Verkehrsverbundes erwägt die Weiterentwicklung des bestehenden Systems und die Integration der datenbasierten Fahrgaststeuerung, um sowohl die Fahrgastzufriedenheit als auch die Attraktivität des Verkehrsverbunds zu steigern und zugleich Digitalisierungskompetenzen aufzubauen. Dazu soll untersucht werden, welches Potenzial die Daten aus der Fahrplan-App allein wie auch in Kombination mit weiteren Datenquellen besitzen. Die Aufgabe wird zunächst an einer bzw. einem Mitarbeiter*in aus der IT-Abteilung übergeben.

A.4.2 Vorgehen der Anwender*innen und benötigte Kompetenzen

Das Vorgehen ist in der folgenden Tabelle 15 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[1]	Um potenzielle bereits bestehende Datenquellen zu identifizieren, wird eine Übersicht der bereits vorhandenen Datenquellen aufgestellt	Datenquellen identifizieren und entscheiden, ob Datenquelle für die datenbasierte Fahrgaststeuerung relevant ist	Kodieren	B.2.1
[2]	und die Daten auf Vollständigkeit und Richtigkeit überprüft.	Unstimmigkeiten in den Daten erkennen	Kodieren	B.3.1
[3]	Es wird reflektiert, ob die bereits vorhandenen Datenquellen genügen, um das Potential zu analysieren	Sich bewusst machen, dass weitere Datenquellen notwendig sein könnten	Kodieren	B.3.1
[4]	und sich dafür entschieden, die Potenzialanalyse zunächst mit den vorhandenen Daten, ohne Einbeziehung externer Quellen, durchzuführen.	Abwägungsprozess, um die vorhandenen Daten bezüglich ihres Potenzials einzuschätzen	Kodieren	B.3.1
[5]	Dabei wird festgestellt, dass die Datenaufbereitung aufgrund der Menge unterschiedlicher Datenquellen ebenso wie die weitere Analyse sehr umfangreich ist und sich dafür entschieden, externe Expertise zu konsultieren.	Grenzen der eigenen Kompetenz erkennen und Expertise einholen	Kodieren	A.3

Tabelle 15: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 4)

A.4.3 Vorgehen der Expert*innen und benötigte Kompetenzen

Das Vorgehen des Data Scientist ist in der folgenden Tabelle 16 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[6]	Zunächst werden die verfügbaren Datenquellen gesichtet,	Überprüfen, in welcher Form Datenquellen vorliegen	Kodieren	B.3.1
[7]	die für die Potenzialanalyse essentiellen Merkmale identifiziert	Abwägen, welche Merkmale für die Fragestellung relevant sind	Kodieren	B.3.2
[8]	und die Daten derartig aufbereitet, dass eine konsolidierte Analysetabelle erstellt werden kann.	Umgang mit verschiedenen Datenquellen in unterschiedlicher Form und Verknüpfung von Datenquellen	Kodieren	B.3.2
[9]	In einem ersten Schritt werden dann zwei Analysepotenziale identifiziert: 1.) Die Analyse der Anfragen und 2.) die Analyse der Netzauslastung,	Hypothesen aus Daten generieren	Kodieren	C.1
[10]	wobei erschlossen wird, dass die Anfragen nicht repräsentativ für alle Fahrgäste sind.	Daten verifizieren	Kodieren	B.3.1
[11]	Dann wird die Häufigkeitsverteilung der Start- und Endpunkte analysiert	Kleinräumlich/-zeitliche Häufigkeitsverteilungen erstellen	Kodieren	C.1
[12]	und jene Verteilung visualisiert (Abbildung 17; Abbildung 18).	Identifikation und Erstellung geeigneter visueller Darstellungen	Kodieren	C.2
[13]	Es wird festgestellt, dass die Analyse der Abfragen keine Störungen berücksichtigt und entsprechend deren Einfluss auf die Abfragen visualisiert (Abbildung 19)	Interpretation der Ergebnisse und Visualisierungen	Dekodieren	D.2/D.3
[14]	Im nächsten Schritt wird dann die stündlich aufgelöste Netzauslastung analysiert	Entwicklung eines Algorithmus zur Rekonstruktion der zurückgelegten Pfade und Simulation der zukünftigen Netzauslas-	Kodieren	C.1

[14]		tung (insbesondere bei Sonderereignissen)		
[15]	und die entsprechende Netzauslastung visualisiert (Abbildung 20).	Identifikation und Erstellung geeigneter visueller Darstellungen	Kodieren	C.2
[16]	Es wird festgestellt, dass die Netzauslastung nur simuliert vorliegt. Dies ist zwar ein Anhaltspunkt für konkrete Handlungsempfehlungen, doch wäre eine Analyse echter Verbindungsdaten geeigneter.	Interpretation der Ergebnisse und Visualisierungen; Rückschlüsse auf die Datenqualität bedingt durch die Herkunft	Dekodieren	D.2/D.3
[17]	Es werden weitere Analysemöglichkeiten identifiziert: Um die Auslastung der Hauptverkehrsader zu analysieren, werden Winkelanalysen als Proxy für die Netzauslastung der Hauptverkehrsader und des Zentrums verwendet.	Data Mining einsetzen, um neue Zusammenhänge zu entdecken	Kodieren	C.1
[18]	Visualisierung der Winkelanalysen (Abbildung 20).	Identifikation und Erstellung geeigneter Darstellungen	Kodieren	C.2
[19]	Es wird erkannt, dass sich auffällige Datenmuster zeigen, die auf verschiedene Phänomene hinweisen können. Jedoch ist die genaue Auslastung unbekannt.	Interpretation der Ergebnisse und Visualisierungen	Dekodieren	D.2/D.3
[20]	Aufbereitung der Ergebnisse	Ergebnisse darstellen	Kodieren	C.3
[21]	Diskussion der Ergebnisse mit dem Verkehrsverbund	Verständliche Kommunikation der Ergebnisse an Fachfremde	Dekodieren	D.1
[22]	In Abstimmung mit den Statistik-Expert*innen leitet der Verkehrsverbund daraus Handlungsempfehlungen ab, wie die Daten kombiniert und für die Planung und Steuerung genutzt werden können.	Aus den Analyseergebnissen werden Handlungsmöglichkeiten für den Verkehrsverbund abgeleitet	Dekodieren	F.1

Tabelle 16: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 4)

A.4.4 Ergebnis

Die folgenden Abbildungen zeigen Daten, die aus Vertraulichkeitsgründen verfälscht wurden.

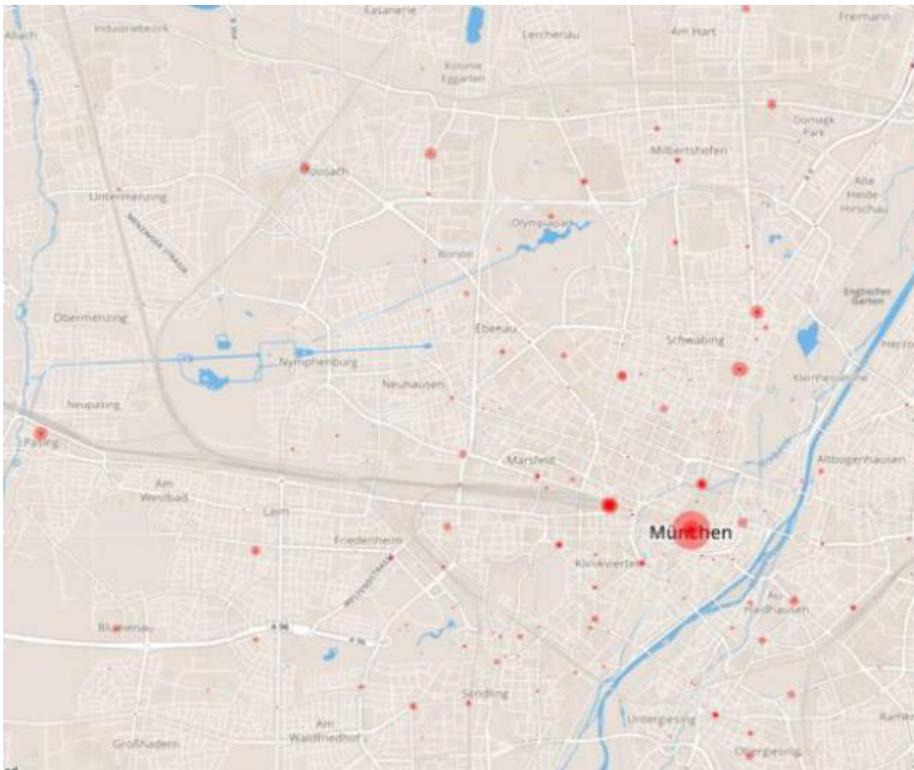


Abbildung 17: Anfrageanalysen der Ziele (Mittwoch 7 bis 10 Uhr)

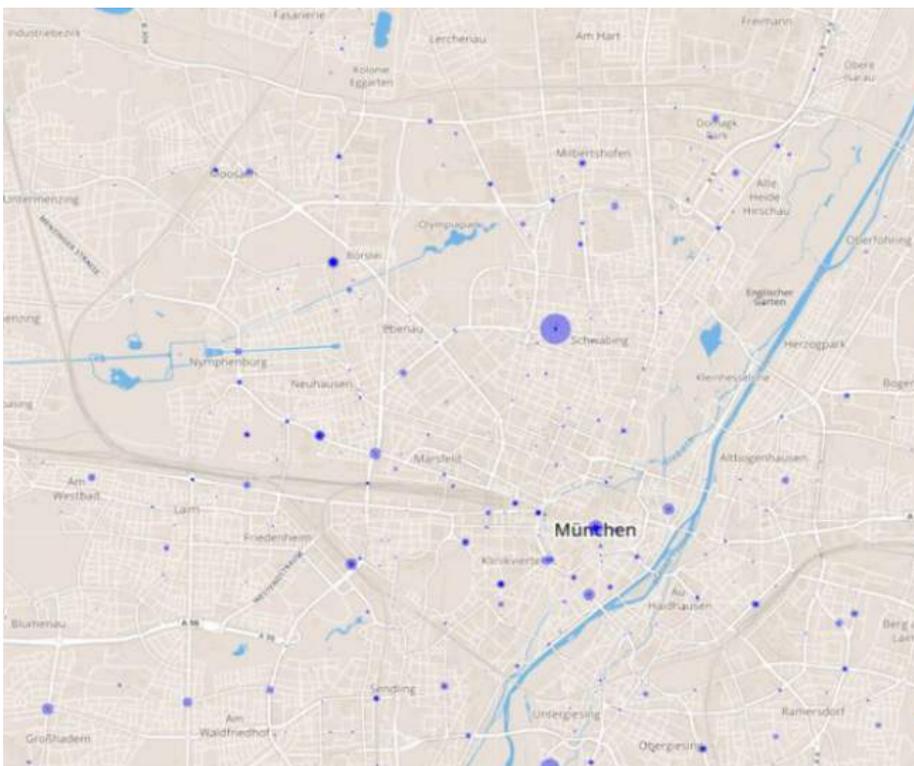


Abbildung 18: Anfrageanalysen der Starts (Mittwoch 7 bis 10 Uhr)

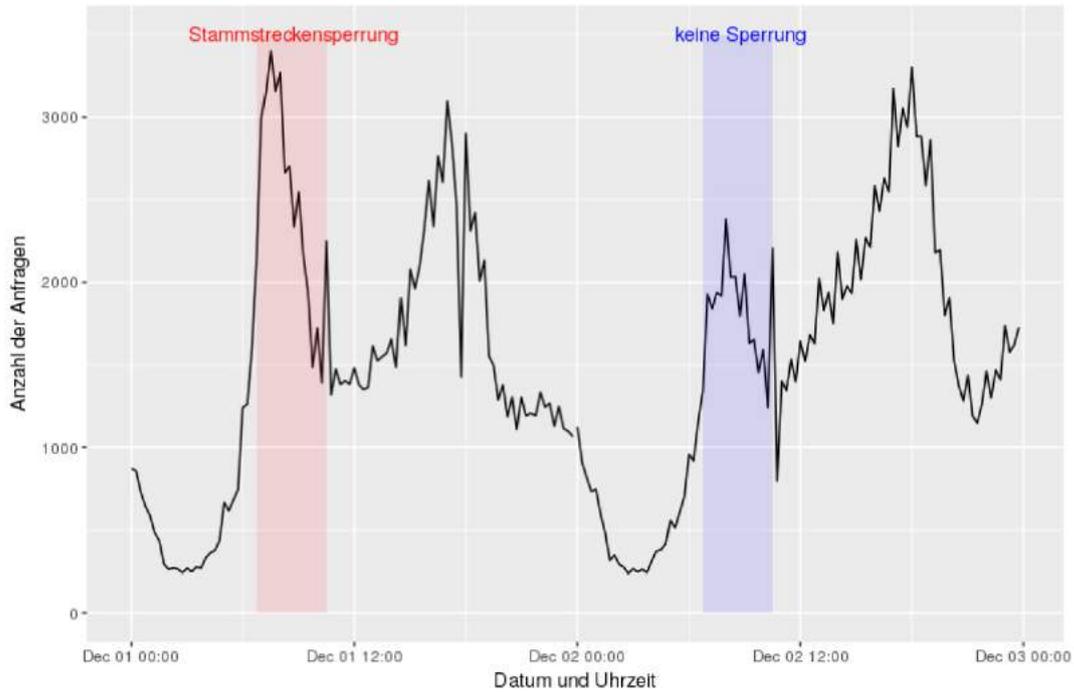


Abbildung 19: Anfrageanalysen - Vergleich von zwei Tagen mit und ohne Sperrung der Hauptverkehrsader

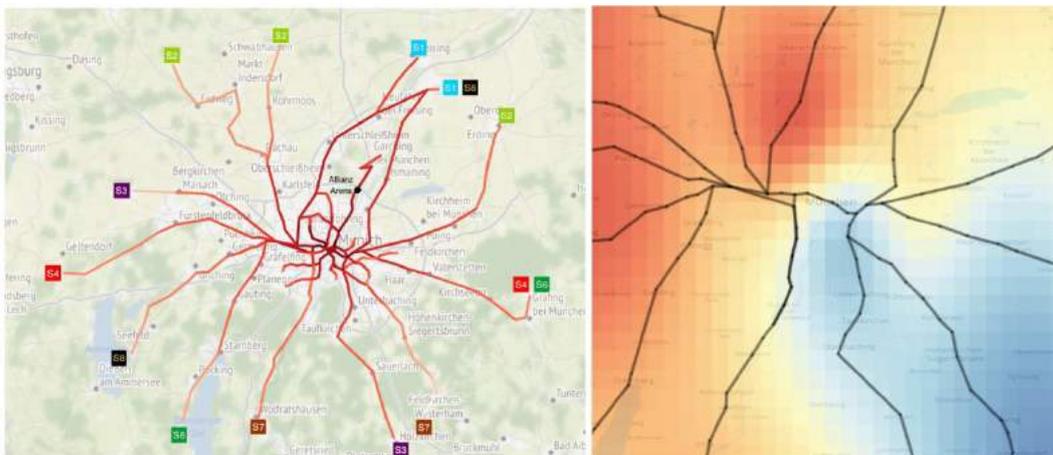


Abbildung 20: Analyse der Netzauslastung (links) und Winkelanalyse zur Auslastungsanalyse des Zentrums (rechts)

Die folgende Tabelle 17 zeigt das Ergebnis der Untersuchung, wie die einzelnen Datenquellen alleine oder in Kombination mit anderen genutzt werden können und was für die Nutzung noch zu tun ist.

Datenquelle	Potenzial	Restriktionen/Lösungsansätze
Trip Requests	<ul style="list-style-type: none"> • Früherkennung Störungen • hochfrequente Auslastungsanalyse • Pendlerstrom-Analyse 	<ul style="list-style-type: none"> • Datensatz nicht repräsentativ für alle Passagiere • Modell für Hochrechnung entwickeln

Points of Interest	Merge mit Trip Requests für alle Analysen nützlich	<ul style="list-style-type: none"> • Koordinaten für die Adressen nicht enthalten • Algorithmus für Adress-Koordinaten-Matching schreiben
Adresskoordinaten	Georeferenzierung der Adressdaten zur Zuordnung der Anfragen zur nächstgelegenen Haltestelle	<ul style="list-style-type: none"> • Parsing-Algorithmus für (kostenpflichtigen) Bezug der Daten von Google notwendig • Algorithmus zur Entfernungsberechnung schreiben
Streckenagent	Unterschiede zwischen Normalbetrieb und Störungstagen erkennen	<ul style="list-style-type: none"> • Meldungen vollständig und zuordenbar? • Störungsmeldungen validieren
Staumelder	<ul style="list-style-type: none"> • Zusammenhänge der Nutzungsmeldungen mit Streckenagent • frühzeitige Störungsprognose für rechtzeitigen Aufbau der Serverkapazität 	<ul style="list-style-type: none"> • Merge von Streckenagent mit Nutzungsmeldungen? • Datenformat erfordert hohen Bereinigungsaufwand • Textmining, Ontologie aufbauen?
Störungsticker	<ul style="list-style-type: none"> • Aufbau einer umfangreicheren Datenbank durch automatischen Download • Analyse der Trip Request-Muster bei Normalbetrieb und Störung 	<ul style="list-style-type: none"> • Parsing-Algorithmus für (kostenfreien) Bezug der Daten von der Webseite/Twitter schreiben • Textmining, um räumlichen Bezug herzustellen

Tabelle 17: Potenziale und Restriktionen der verschiedenen Datenquellen des Verkehrsverbundes

A.5 Psychologie: Ethik in der Forschung

A.5.1 Fragestellung

Eine Psychologie-Professorin einer Universität wendet sich an Statistik-Expert*innen mit der Bitte, die Ergebnisse einer Dissertation zu überprüfen. Ihrer Aussage nach handelt es sich um herausragende Befunde, die eine wichtige Theorie bestätigen, „nur dummerweise scheinen sämtliche Daten verloren. Das scheint mir (wie vielen anderen) nun nicht wirklich allzu wahrscheinlich zu sein, und die genaueren Umstände lassen es denkbar erscheinen, dass die Daten erfunden worden sein könnten. Nun habe ich einmal gehört, dass es ausgewiesenen Statistik-Expert*innen offenbar gelingen kann, aufgrund publizierter Korrelationstabellen, Streuungsmaße, Reliabilitäten etc. die Plausibilität dessen abzuschätzen, ob die berichteten Befunde auf echten Datentabellen (die möglicherweise fabriziert sein könnten; nur dann wird es sich eben nicht mehr belegen lassen) beruhen oder ob sie komplett frei erfunden sein könnten. Bei der fraglichen Dissertation handelt es sich vorwiegend um Experimente, also vorwiegend auf Varianz- und Regressionsanalysen und t-Tests.

Die vorliegende Arbeit umfasst im Wesentlichen Prä-Post-Analysen von Messungen einer Experimentalgruppe und einer Kontrollgruppe. In einem Experiment sollten die Auswirkungen negativer Emotionen auf die Performanz von Testpersonen in verschiedenen motorischen Tests untersucht werden. Dabei wurde beispielsweise die Kraft, die eine Versuchsperson an einem Trainingsgerät aufwenden konnte, gemessen und es wurde untersucht, ob die psychologische Regulation von induzierten Tendenzen wie intrusive Gedanken, Gefühle und Mimik dazu führte, dass die Kraft unter dem Einfluss einer experimentell erzeugten negativen Emotion gegenüber dem Prä-Test ohne eine solche Bedingung nachließ.

Die Schritte, welche die Professorin unternimmt, sind im Hinblick auf die propagierte Bedeutung von Ethik und Werthaltung für Data Literacy sehr bedeutsam. Das erforderliche Niveau an Data Literacy seitens der Anwenderin ist deshalb hoch.

A.5.2 Vorgehen der Anwender*innen und benötigte Kompetenzen

Das Vorgehen ist in der folgenden Tabelle 18 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[1]	Zunächst werden die statistischen Ergebnisse im Hinblick auf deren Bedeutung für die psychologische Forschung bewertet	Erkennen, dass die Ergebnisse einen hohen Wertbeitrag für die Forschung leisten	Dekodieren	F.1
[2]	und entschieden, dass die Daten so werthaltig sind, dass sie vertieft ausgewertet werden sollen.	Nächste Schritte für die Forschungstätigkeit ableiten	Dekodieren	F.2
[3]	Bewertung der Umstände (z.B. Umgang mit erhobenen Daten)	Erkennen, dass der behauptete Totalverlust von	Dekodieren	E.2

[3]	anhand der Regeln wissenschaftlich sauberen Arbeitens und Reflexion, ob unsauberes Arbeiten mit derartigen Ergebnissen vereinbar ist.	Daten im Gesamtkontext fragwürdig erscheint		
[4]	Aufgrund von Skepsis wird die Plausibilität jener „Superbefunde“ weiter hinterfragt und mit üblichen Ergebnissen derartiger Experimente verglichen.	Wissen, was man bei Kraft-Tests erwarten kann, und Bewerten der gefundenen Effektstärken	Dekodieren	E.3
[5]	Klarstellung, dass ein Fall von Datenbetrug an der Fakultät nicht tragbar wäre.	Ethisches Bewerten der möglichen Folgen eines Datenbetrugs	Dekodieren	F.3
[6]	Es wird angenommen, dass Daten-Expert*innen wissen könnten, wie man mutmaßliche Datenfälschungen anhand der Ergebnisse aufdecken kann.	Handlungsmöglichkeit identifizieren, um die mögliche Täuschung aufzudecken	Dekodieren	F.1
[7]	Identifikation der nötigen Informationen, die Expert*innen benötigen, um die Plausibilität statistischer Ergebnisse zu prüfen,	Wissen über statistische Kennzahlen und deren Aussagekraft bzw. Schwachstellen	Dekodieren	E.1
[8]	Es wird dafür optiert, eine Begutachtung durch qualifizierte Expert*innen durchführen zu lassen,	Grenzen der eigenen Kompetenz erkennen und Expert*innenrat einholen	Kodieren	A.3
[9]	Welche zunächst inoffiziell beauftragt werden, um den potenziellen Schaden in Grenzen zu halten.	Bewerten, welche Folgen ein möglicherweise negatives Gutachten für die Fakultät hätte.	Dekodieren	F.3

Tabelle 18: Vorgehen der Anwender*innen und benötigte Kompetenzen (Fallstudie 5)

A.5.3 Vorgehen der Expert*innen und benötigte Kompetenzen

Das Vorgehen der Statistiker*innen ist in der folgenden Tabelle 19 systematisch nach den jeweils zugrundeliegenden Kompetenzen aufgeschlüsselt.

Schritt	Beschreibung	Kompetenz	Prozess	Zuordnung
[10]	Die Statistik-Expert*innen lesen die Dissertation und planen ihr Vorgehen.	Überlegen, welche Vorgehensweise das Problem lösen kann	Kodieren	A.3

[11]	Identifikation möglicher Ansatzpunkte, indem die Aussagekraft der berichteten Ergebnisse bewertet wird	Bewerten, welche Rückschlüsse möglich sind, weil zwischen einzelnen berichteten Kennwerten bestimmte Beziehungen bestehen	Dekodieren	D.1
[12]	und Informationen zur Methodik aus dem Fließtext extrahiert werden	Verbale Beschreibung von Analysen entschlüsseln	Dekodieren	D.3
[13]	sowie aus den Grafiken und tabellarischen Darstellungen.	Visuelle Darstellung auf mehreren Ebenen entschlüsseln (inhaltlich, formal: Erkennen der verwendeten Analyse Software).	Dekodieren	D.2
[14]	Es wird überlegt, welche Einschränkungen die Darstellungsform durch einen Informationsverlust induziert	Bewerten, wie mit gerundeten Ergebnissen umzugehen ist	Dekodieren	E.1
[15]	Anwendung von Fachwissen bezüglich der Beziehungen der berichteten Kennwerte,	Statistische Analysen aufgrund gegebener Informationen entschlüsseln	Dekodieren	D.1
[16]	indem alle prüfbar Beziehungen nachgerechnet	Statistische Analysen mit Tertiärdaten (d.h. aggregierten Daten) durchführen	Kodieren	C.1
[17]	sowie Unplausibilitäten hinsichtlich möglicher Ursachen beurteilt werden.	Daten-Transformationen bewerten, z.B. Rundungsfehler von „echten“ Fehlern abgrenzen	Dekodieren	E.1
[18]	Anschließend wird anhand des Gesamtbildes evaluiert, ob eine Datenfälschung anzunehmen ist.	Bewerten, ob die Fehler wahrscheinlicher auf unsauberes Arbeiten oder auf wissenschaftliches Fehlverhalten zurückzuführen sind.	Dekodieren	E.2/E.3
[18]				
[19]	Dokumentation des Vorgehens sowie der Ergebnisse in einem detaillierten Bericht für die Anwender	Vorgehen, Methodik und Ergebnisse in einem für den Anwender verständli-	Kodieren	C.3

	derin.	chen Text zusammenfas- sen		
--	--------	-------------------------------	--	--

Tabelle 19: Vorgehen der Expert*innen und benötigte Kompetenzen (Fallstudie 4)

Im Anschluss entscheidet die Professorin, das Gutachten der Universitätsleitung zu übergeben, um Konsequenzen aus dem mutmaßlichen akademischen Fehlverhalten zu ziehen¹⁰. Zusätzlich thematisiert sie die Bedeutung von Data Literacy für ihre Kolleg*innen, die oftmals keine Statistik-Expert*innen sind, aber Abschlussarbeiten betreuen, in denen neuartige Datenquellen und Analysemethoden verwendet werden, in einem Vortrag auf einer Fachkonferenz.

A.5.4 Ergebnis

Die Ergebnisse des Gutachtens sind im Folgenden zusammengefasst, wobei sämtliche Hinweise, die Rückschlüsse auf die Identität der beteiligten Personen und Institutionen zulassen würden, entfernt wurden.

Vorgehen

Die Analysesoftware wurde in der Dissertation nicht angegeben, aber die Tabellenstruktur und Abbildungsformate sind typisch für SPSS, so dass geprüft werden kann, welche Angaben dort standardmäßig ausgegeben werden. Im Text wurden je zwei Dezimalstellen angegeben, so dass Rundungsdifferenzen zu berücksichtigen sind. Augenmerk wird deshalb weniger auf (kleine) Abweichungen gelegt als vielmehr auf Werte, die von Statistikprogrammen ausgegeben werden (z.B. korrekte Zahl der Freiheitsgrade bei statistischen Tests, die man nur abschreiben muss) und auf Verhältnisse zwischen Ergebnissen (erwartete Unterschiede, die vorhanden sein müssen, z.B. muss das Ergebnis einer Division größer werden, wenn der Zähler durch einen kleineren Nenner geteilt wird).

SPSS erlaubt nur Auswertungen auf Basis von Daten, aber die Software R erlaubt das Nachrechnen von Ergebnissen, wenn man die Formeln und Zusammenhänge versteht. So kann beispielsweise überprüft werden, welche Teststatistiken sich für verschiedene t-Tests (gleiche/ungleiche Varianz) sowie für die ANOVA ergeben. Auch kann die Kenngröße „partielles Eta-Quadrat“ nachgerechnet werden. Auch kann der Zusammenhang bestimmter deskriptiver Kennwerte, z.B. Spannweite und Standardabweichung, genutzt werden, um Angaben auf Plausibilität zu prüfen.

Beispiel 1 (benötigtes Data-Literacy-Kompetenzniveau: gering bis mittel)

Im Text wurden deskriptive Statistiken zur Teilnehmerzahl berichtet:

- $n=140$, Mean = 24.8, SD = 0.34, age range 20 – 36 Jahre

Als Faustregel kann bei annähernd symmetrisch verteilten Beobachtungen angenommen werden, dass die range (Spannweite) in etwa sechsmal der SD (Standardabweichung) entspricht. Hier liegt die Spannweite bei 16, aber $6 \times 0,34 = 2,04$. Die Standardabweichung ist zudem genau dann minimal, wenn alle Werte außer dem Minimum und dem Maximum den Durchschnitt von Minimum und Maximum annehmen (hier: 28). Der minimal erzielbare Wert der Standardabweichung liegt dann bei 0,96, was deutlich über dem berichteten Wert von 0,34 liegt. Die Wertekombination ist

¹⁰ In der realen Situation, die der Fallstudie zugrunde liegt, wurden keine Konsequenzen gezogen, da ein Reputationsschaden befürchtet wurde.

rechnerisch unmöglich. Womöglich handelt es sich um einen Tippfehler, aber es werden ähnliche Inkonsistenzen an weiteren Stellen in der Arbeit gefunden.

Beispiel 2 (benötigtes Data-Literacy-Kompetenzniveau: mittel bis hoch)

Die Fragestellung lautete, ob eine Gruppierungsvariable „Treatment“ die Differenz zweier Vorher-Nachher-Messungen beeinflusst, d.h. ob das Delta der Messungen in Versuchs- und Kontrollgruppe verschieden ist. Gewählt wurde zunächst ein t-Test zum Vergleich der durchschnittlichen Differenzen, was nicht dem Standard-Ansatz der Statistik (Generalisiertes lineares Modell mit Messwiederholung) entspricht.

Es wurde im Text angemerkt, dass Kovariate „Ausgangsniveau“ in einer ANCOVA (Analysis of Covariance, ein weiteres Verfahren zur Analyse von Prä-Post-Messungen) signifikant sei, was bedeutet, dass Personen mit hohen Messwerten (prä) auch hohe Messwerte (post) besitzen und umgekehrt. Berichtet wurden Mittelwerte und Standardabweichungen der Messungen prä/post getrennt nach Versuchs- und Kontrollgruppe.

Daraus lassen sich nachträglich berechnen¹¹:

- Mittelwert der Differenz post – prä je Gruppe
- Standardabweichung (SD) der Differenz post – prä je Gruppe
- Kovarianz der Messungen prä und post je Gruppe
- Korrelation der Messungen prä und post je Gruppe
- Beta (Steigungsparameter) der Regression prä auf post je Gruppe

In Fallzahlplanung in klinischen Studien ist es üblich, dass bei einer unbekanntem Korrelation prä/post der Messwerte von Patient*innen häufig ein Wert von 0,5 angenommen wird, d.h. es besteht ein schwacher bis mäßiger Zusammenhang zwischen den Ergebnissen vor/nach Intervention bei den jeweiligen Patient*innen.

	Mean (t1)	SD (t1)	Mean (t2)	SD (t2)	Mean (t2-t1)	SD (t2-t1)	Cov(t1,t2)	Corr(t1,t2)	Sig. (approx.)	Beta (approx.)
EG (n=60)	86.36	29.94	82.66	29.52	-3.70	5.0	871.42	.99	<.001	0.97
CG (n=60)	84.38	25.42	83.46	25.60	-0.94	1.0	650.27	>.99	<.001	1.01
Gesamt (n=120)	85.37	27.77	83.06	27.63	-2.32	3.61	764.79	>.99	<.001	0.99

Tabelle 20: Ergebnisse¹² Experiment 1

Das Ergebnis zeigt für zwei Experimente eine sehr ungewöhnliche Gesamtkonstellation: Eine Korrelation von 0,99 oder größer würde eine nahezu perfekte Vorhersage der Messwerte (post) aus den Messwerten (prä) für beide Gruppen erlauben. Für reale Daten aus psychologischen Experimenten erscheint das fragwürdig. Zudem wäre der Effekt der Kovariate „Ausgangsniveau der Messung“ hier signifikant (da ein signifikanter Koeffizient Beta vorliegt), aber die Interaktion mit

¹¹ Durch Auflösen der bekannten Formeln für die jeweiligen statistischen Analysen nach den gesuchten Kennwerten.

¹² EG = Experimentalgruppe, CG = Kontrollgruppe, Mean = Mittelwert, SD = Standardabweichung, Cov = Kovarianz, Corr = Korrelation, Sig = Signifikanz/p-Wert, Beta = Steigungsparameter der Regression, t1 Messung prä, t2 = Messung post.

Gruppe nicht. Dies bedeutet: Versuchspersonen, die bei der ersten Messung hohe Werte aufwiesen, haben auch hohe Werte in der zweiten Messung, unabhängig davon, ob sie ein Treatment erhalten haben oder nicht.

Eine Korrelation von 0,99 oder größer würde eine nahezu perfekte Vorhersage der Messwerte (post) aus den Messwerten (prä) für die Kontrollgruppe erlauben. Für reale Daten aus psychologischen Experimenten erscheint das wiederum fragwürdig. Zudem wäre der Effekt der Kovariate „Ausgangsniveau der Messung“ hier signifikant (da ein signifikanter Koeffizient Beta vorliegt), zugleich auch die Interaktion mit der Gruppe, weil die Werte von Beta in beiden Gruppen stark unterschiedlich sind. Dies bedeutet: Versuchspersonen der Kontrollgruppe, die bei der ersten Messung hohe Werte aufwiesen, haben auch hohe Werte in der zweiten Messung, während Versuchspersonen in der Experimentalgruppe tendenziell niedrigere Messwerte (post) aufweisen, je höher ihre Messwerte (prä) waren.

	Mean (t1)	SD (t1)	Mean (t2)	SD (t2)	Mean (t2-t1)	SD (t2-t1)	Cov(t1,t2)	Corr(t1,t2)	Sig. (approx.)	Beta (approx.)
CG (n=60)	23.80	4.16	24.88	4.27	1.08	1.0	17.27	.97	<.001	1.00
EG (n=60)	24.18	5.21	21.28	3.83	-2.90	7.11	-4.37	-.22	.046	-0.16
Gesamt (n=120)	23.99	4.71	23.08	4.06	-0.91	5.08	9.34	.49	.045	0.42

Tabelle 21: Ergebnisse Experiment 2

(EG = Experimentalgruppe, CG = Kontrollgruppe, Mean = Mittelwert, SD = Standardabweichung, Cov = Kovarianz, Corr = Korrelation, Sig = Signifikanz/p-Wert, Beta = Steigungsparameter der Regression, t1 Messung prä, t2 = Messung post)

Anders als an weiteren Stellen in der Arbeit wurden diese Ergebnisse der ANCOVA (insbesondere die signifikanten Koeffizienten Beta) nicht im Text erwähnt, obwohl sie diskussionswürdig wären. Eine Datensituation könnte ein Hinweis auf einen künstlich erzeugten Datensatz sein. Dazu müsste man nur in jeder Gruppe einen relativ konstanten Wert abziehen bzw. addieren – in der Kontrollgruppe einen kleineren, in der Experimentalgruppe einen größeren. Damit würden sich derart „unnatürlich“ hohe Korrelationen der Prä-Post-Messungen ergeben.

Abschließende Bewertung

Viele Auffälligkeiten sind mit Rundungsfehlern (gerade noch) erklärbar. Ein Mangel an statistischem Verständnis ist offenkundig:

- Tests wurden vielfach nicht passend gewählt (z.B. wurden ungleiche Varianzen in den Gruppen ignoriert)
- Nicht sinnvolle Kennwerte wurden berichtet (z.B. wurden Paarvergleiche mit F-Tests durchgeführt, dazu aber Mittelwert und Standardabweichung angegeben, was die üblichen Angaben bei t-Tests sind).

Einige Ergebnisse sind rechnerisch unmöglich. Eventuell handelt es sich um Tippfehler, aber es fällt auf, dass es mehrfach auf dieselbe Art und Weise vorkommt. Freiheitsgrade sind teilweise falsch angegeben. Diese werden standardmäßig von der Analysesoftware ausgegeben und müssten lediglich korrekt abgetippt werden, unabhängig davon, ob sie verstanden wurden.

Es scheinen zwei Erklärungen möglich:

- Es wurde sehr unsauber gearbeitet, was sich darin zeigt, dass an rund 20 Stellen in einer ca. 80-seitigen Arbeit Werte fehlerhaft abgetippt wurden.
- Die Daten wurden (teilweise) erfunden, was technisch möglich wäre, indem bei „unerwünschten“ Ergebnissen von Prä-Post-Messungen eine Konstante addiert wurde.

Welcher Fall vorliegt, ist nicht mit Sicherheit zu sagen. Es wird allerdings angeraten, die Darstellung der Ergebnisse so nicht zu akzeptieren, weil entweder falsche Angaben gemacht wurden (Standardabweichung der Differenzen in Experimentalgruppe und Kontrollgruppe in Kombination mit den Standardabweichungen der Messungen selbst) oder weil bei der ANCOVA wichtige Punkte unterschlagen wurden (eine signifikante Interaktion muss im Modell berücksichtigt werden, was in mindestens einem Experiment nicht gemacht wurde) oder weil die Daten nicht echt sein können.

Anhang B: Vorschlag für Kompetenzniveaus

Der Deutsche Qualifikationsrahmen (DQR) definiert acht Niveaus zur Einordnung von Qualifikationen in das deutsche Bildungssystem („Deutscher Qualifikationsrahmen - DQR-Niveaus“, o. J.). Es werden darin recht allgemeine Anforderungen beschrieben, die erfüllt werden müssen, wenn eine Qualifikation ein entsprechendes Niveau erlangen soll. Diese Anforderungen sind in Fachkompetenzen (Wissen und Fertigkeiten) und personale Kompetenzen (Sozialkompetenz und Selbständigkeit) aufgeteilt. Sollen die Kompetenzniveaus etwas vereinfacht werden, so könnte eine praxisorientierte Unterscheidung folgende Stufen umfassen:

- (1) [Datenquellen / Analysewerkzeuge / Formen der Visualisierung / Stufen von Analyse wie descriptive, diagnostic, predictive, prescriptive bzw. unsupervised, supervised, reinforced learning / Möglichkeiten der Qualitätsprüfung von Daten ...] kennen und wissen, welchen Beitrag sie auf der jeweiligen Wertschöpfungsstufe bzw. in dem jeweiligen Prozessschritt leisten können = **Wissen** von Fakten, Methoden, Theorien, die der jeweiligen Kompetenz zuzuordnen sind
 - a. Bsp. A: kennt verschiedene Visualisierungsmethoden und weiß, wann man sie anwendet.
 - b. Bsp. B: kennt die wesentlichen Regeln des Datenschutzes und der Datensicherheit

- (2) Fähigkeit, Anforderungen an den konkreten Verarbeitungsprozess (Datenbeschaffung, Datenbereinigung, Datenanalyse, Datenvisualisierung, Interpretation, Entscheidungsfindung) im Dialog mit Expert*innen zu spezifizieren = (angeleitete) **Analyse** von Sachverhalten auf das wesentliche Element und **Verstehen** der Bedeutung von Informationen bzw. erkennen von deren Zusammenhängen
 - a. Bsp. A: kann Expert*innen für Visualisierung erklären, welche Botschaft mittels einer Visualisierung transportiert werden soll und mit ihnen zusammen eine geeignete Visualisierung auswählen
 - b. Bsp. B: kann Expert*innen für Datenschutz erklären, wozu Daten erhoben werden sollen und mit ihm zusammen die Datenschutzerfordernungen spezifizieren

- (3) Fähigkeit, das Werkzeug aus [1] in einer neuen Standardsituation korrekt anzuwenden / es richtig zu bedienen = **Anwenden** des Wissens auf konkrete, neue Aufgaben und Problemstellungen
 - a. Bsp. A: kann Visualisierungen auf neue Daten korrekt anwenden

- b. Bsp. B: kann in einer Datenerhebungs-Situation überprüfen, ob die Datenschutzerfordernngen erfüllt sind
- (4) Fähigkeit, das Werkzeug zu erstellen bzw. zu überarbeiten = **Synthese** bzw. kreative Kombination vorhandener Elemente
- a. Bsp. A: kann Visualisierungen auf neue Daten korrekt anwenden
 - b. Bsp. B: kann in einer Datenerhebungs-Situation überprüfen, ob die Datenschutzerfordernngen erfüllt sind
- (5) Fähigkeit, das Werkzeug bzw. die Methode als Fachperson zu vermitteln = **Bewertung** von fremden Aufgabenstellungen und Vermitteln der Kenntnisse
- a. Bsp. A: kann als Visualisierungsfachperson/Data Designer Anwendende auf Stufe (2) beraten, um geeignete Visualisierung zu finden, und dabei vermitteln, warum welche Kriterien zu beachten sind
 - b. Bsp. B: kann als Datenschutzzfachperson Anwendende auf Stufe (2) beraten, um die relevanten Datenschutzerfordernngen festzulegen, und dabei vermitteln, warum welche Kriterien zu beachten sind

Anhang C: Data Literacy Framework

C.1 Kompetenzfeld A: Datenkultur etablieren – Vom System zu messbaren Objekten

Dies umfasst die Intention Datenkultur zu etablieren. In der ersten Stufe steht die Identifikation von Datenanwendungen. Hierbei sollen Wissenslücken und Hintergrundinformationen identifiziert werden, welche die Basis für eine konkrete Aufgabenstellung liefern. In der zweiten Stufe werden z. B. Anforderungen definiert und an Sachverständige kommuniziert und die Anwendung wird von anderen Aufgaben abgegrenzt. Diese Stufe spezifiziert die Datenanwendungen. Die dritte Stufe umfasst die Planung und Koordination der Datenanwendung.

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
A1: Daten-Anwendung identifizieren	Identifiziert Wissenslücken und Hintergrundinformationen, identifiziert auf dieser Basis eine konkrete Aufgabenstellung, die mit Hilfe von Daten gelöst werden kann, besitzt eine Vorstellung vom möglichen Wertbeitrag der Daten	Tiefes theoretisches und praktisches Fachwissen über das Anwendungsgebiet bzw. die Disziplin sowie ggf. verwandte Disziplinen	Fähigkeit, relevante Wissenslücken zu identifizieren und zu bewerten hinsichtlich des möglichen Wertbeitrags einer Datenanalyse Fähigkeit, relevante von irrelevanten Informationen über das System zu trennen	Offenheit dafür, fachspezifische Fragestellungen mit Hilfe von Daten und deren Analyse zu beantworten Wille, aus Daten zu lernen Bereitschaft, bestehende Regeln und Prozessabläufe zu hinterfragen Bereitschaft, Nicht-Wissen zuzugeben und zu akzeptieren	(1) Erkennt naheliegende Anwendungsfälle, z. B. durch Kopieren von Fragestellungen aus der Literatur, die auf typischen Problemen und Datenquellen beruhen (2) Erkennt ungewöhnliche Anwendungsfälle, etwa durch kreative Neukombination bekannter Anwendungen (3) Erkennt disruptive Anwendungsfälle, etwa durch Antizipation neuer Technologien, Datenquellen, Nutzergruppen

<p>A2: Daten-Anwendung spezifizieren</p>	<p>Definiert Minimal- und optionale Anforderungen, definiert Abgrenzungen zu anderen Aufgaben, strukturiert den Prozessablauf in Objekte und deren Beziehungen, leitet messbare Objekte und Hypothesen über deren Zusammenhänge ab, kommuniziert die Anforderungen gegenüber Sachverständigen</p>	<p>Wissen über konkrete praktische Abläufe, Beteiligte und Wirkmodelle</p> <p>Wissen über Probleme, die aus einem falschen Verständnis des Systems resultieren können</p> <p>Wissen über die Informationen, die (Daten-)Sachverständige zur Messung und Modellierung des Systems benötigen</p>	<p>Fähigkeit, komplexe Aufgabenstellungen in einzelne Elemente zu zerlegen und diese Elemente sowie deren Beziehungen zu beschreiben</p> <p>Fähigkeit, nicht bzw. nur teilweise kodifiziertes Sachverständigenwissen über Systeme, deren Elemente und Zusammenwirken in (Hypothesen über) Regeln zu formalisieren</p> <p>Fähigkeit, das benötigte Wissen zum Verständnis einer Aufgabenstellung in einem interdisziplinären Team bzw. an einen (Daten-) Sachverständigen zu kommunizieren</p>	<p>Bereitschaft, Wissen mit anderen zu teilen</p> <p>Bereitschaft, den Ergebnissen von Datenanalysen zu vertrauen, auch wenn sie nicht in jedem Detail verstanden werden</p> <p>Bereitschaft, die Grenzen der Aussagekraft von Datenanalysen zu akzeptieren</p>	<p>(1) Kann einfache Fragestellungen mit wenigen, klar abgrenzbaren Elementen und wenigen, direkten Beziehungen spezifizieren</p> <p>(2) Kann komplexe Fragestellungen mit teils verschachtelten Elementen und teils indirekten oder nichtlinearen, statischen Beziehungen spezifizieren</p> <p>(3) Kann hochgradig komplexe Fragestellungen mit einer Vielzahl von komplexen Objekten, sich dynamisch verändernden Beziehungen und Rückkoppelungen spezifizieren</p>
<p>A3: Daten-Anwendung koordinieren</p>	<p>Planung und Koordination eines Datenprojekts, ggf. mit Beteiligung von weiteren Personen (aus interdisziplinären Bereichen))</p>	<p>Kenntnis über Fähigkeit (Stärken/ Schwächen) von Mitarbeitenden</p> <p>Kenntnis über die Expertise (Fachbereich) der jeweils Mitarbeitenden</p> <p>Zeitmanagement</p> <p>Auswahl geeigneter Tools</p>	<p>Fähigkeit, eine sinnvolle Zuweisung von Aufgaben zu verschiedenen Mitarbeitenden durchzuführen, basierend auf deren Kompetenzen</p> <p>Fähigkeit, die Erfahrungen aus vorangegangenen Projekten miteinzubringen und zu verwenden, um das Projekt/die Kollaboration effizienter zu gestalten</p> <p>Fähigkeit, mit Kollaboration/ Versionierungstools wie git umgehen zu können</p>	<p>Bereitschaft, sich mit Problemen von einzelnen Fachleuten auseinanderzusetzen</p> <p>Offenheit für Wünsche anderer Mitarbeiter</p> <p>Bereitschaft, in Notsituationen auszuhelfen</p>	<p>(1) Kann ein Datenprojekt planen und koordinieren, das von einem einzelnen (Daten-) Fachperson bearbeitet wird</p> <p>(2) Kann ein Datenprojekt mit wenigen Beteiligten, vornehmlich Datenfachleute, deren Interessen konvergieren, planen und koordinieren</p> <p>(3) Kann ein Datenprojekt mit vielen, interdisziplinären Beteiligten und divergierenden Interessen planen und koordinieren</p>

Tabelle 22: Kompetenzfeld A – Datenkultur etablieren

C.2 Kompetenzfeld B: Daten bereitstellen – Von messbaren Objekten zu Daten

Dies umfasst die Bereitstellung von Daten. Die erste Stufe befasst sich mit der Konzipierung und ist zweigeteilt in die Modellierung der Datenanwendung und die Einhaltung des Datenschutzes und -sicherheit. Die zweite Stufe beinhaltet die Beschaffung der Daten, genauer, die Identifikation von Datenquellen und Integration der Daten. Die Standardisierung der Daten ist die dritte Stufe. Diese umfasst die Verifizierung und Aufbereitung der Daten.

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
B1.1: Daten-Anwendung modellieren	Bildet die messbaren Objekte in Variablen mit definierbaren Eigenschaften und deren Beziehungen in einer Modellstruktur ab	<p>Wissen über die Beziehungen zwischen realen Objekten und digitalen Repräsentationen dieser Objekte</p> <p>Wissen, dass bei der Messung von Objekten bzw. deren Eigenschaften Information verloren geht und dass ein Auswahl- und Bewertungsprozess nötig ist, auf welche Information verzichtet werden kann</p> <p>Wissen über mögliche Verzerrungen, die z. B. bei Befragungen oder crowd-generierten Daten auftreten</p> <p>Wissen, welche Arten von Fragen welche Datenstrukturen und -perspektiven erfordern (z. B. Kunden- oder Transaktions-sicht), je nachdem was das Objekt ist</p>	<p>Fähigkeit, die Anforderungen von Fachleuten zu erfassen</p> <p>Fähigkeit, ein Prozessmodell in einem Datenmodell abzubilden</p> <p>Fähigkeit, die relevanten Prozess-charakteristika in Daten abzubilden</p> <p>Fähigkeit, die für die Fragestellung erforderliche Sicht auf die Daten zu bestimmen (z. B. historische Datensichten für Prognosen)</p> <p>Fähigkeit, die nötige Granularität der Daten zu bestimmen</p>	<p>Bereitschaft, Entscheidungen hinsichtlich der zu messenden Information zu treffen</p> <p>Bereitschaft, Informationsverluste im Prozess der Messung abzuwägen und zu akzeptieren</p> <p>Bereitschaft, sich Fachbegriffe aus verschiedenen Disziplinen anzueignen und die eigene Kommunikation anzupassen an die Kenntnisse der involvierten Fachleute einschließlich der Bereitschaft, auf Präzision zugunsten der Verständlichkeit zu verzichten</p> <p>Bereitschaft, Restriktionen zu akzeptieren z. B. aufgrund der Abgrenzung der Fragestellung, sowie Bereitschaft, zusätzliche Spezifikationen, Erweiterungen oder Einschränkungen zu kommunizieren und ggf. gegen Widerstände durchzusetzen</p>	<p>(1) Kann zu Modellen einfacher Fragestellungen korrespondierenden Variablen und einfache funktionale Beziehungen in Form von Hypothesen bestimmen</p> <p>(2) Kann zu komplexeren Fragestellungen geeignete Variablen und zielorientierte Hypothesen ableiten, die sich statistisch testen lassen</p> <p>(3) Kann zu höchst komplexen Fragestellungen verschiedene mögliche Variablen und alternative Hypothesensysteme erstellen, wobei die möglichen Modelle und Testverfahren antizipiert werden</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
B1.2: Datenschutz und -sicherheit einhalten	Beachtet Richtlinien für sichere und ethisch fundierte Datenverarbeitung und setzt sie sinngemäß um, wo keine eindeutigen Richtlinien definiert sind	<p>Wissen, welche Kriterien besonders schützenswerte Daten auszeichnen</p> <p>Wissen, welche Datenschutz- und Datensicherheitsanforderungen für die jeweilige Datensituation erforderlich sind</p> <p>Wissen, welche statistischen und technischen Möglichkeiten bestehen, um Daten zu schützen und zu sichern</p>	<p>Fähigkeit, Datenschutz- und Datensicherheitsanforderungen in einer konkreten Situation anzuwenden</p> <p>Fähigkeit, Datenschutz und Datensicherheit sinngemäß umzusetzen, wenn für eine Situation keine eindeutige Regelung existiert</p>	<p>Bereitschaft, sich an Datenschutz und Datensicherheit sowie ethischen Grundsätzen zu orientieren, auch wenn keine klaren Regeln für die konkrete Situation gegeben sind bzw. deren Einhaltung nicht überprüft wird</p> <p>Datenschutz, Datensicherheit und informationelle Selbstbestimmung als Werte begreifen</p> <p>Bereitschaft, Informationsverluste aus ethischen bzw. rechtlichen Gründen zu erzwingen</p> <p>Bereitschaft, die Entwicklung neuer Technologien zum Datenmanagement zu verfolgen und sich eigenständig weiterzubilden</p>	<p>(1) Erkennt grobe Verletzungen des Datenschutzes</p> <p>(2) Kennt grundlegende Regeln, die beim Datenschutz eingehalten werden müssen und ist sich grundsätzlich bewusst, welche Daten wie verwendet werden dürfen oder wann Vorsicht geboten ist</p> <p>(3) Besitzt fundiertes Wissen über Datenschutz und verfügt über genug Kompetenzen, so dass die Verantwortung im Bereich Datenschutz für ganze Projekte übertragen werden kann</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeich- zeichnung	Beschreibung	Beispiele für Wissen [„Knowledge“]	Beispiele für Fähigkeiten [„Skills“]	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
B.2.1: Daten- quellen identifi- zieren	Identifiziert verschiedene gängige und neuartige Daten- quellen (intern, extern) und bewertet deren Zugänglichkeit, Relevanz und Nutzbarkeit	<p>Wissen über mögliche Datenquellen</p> <p>Wissen über Suchmaschinen</p> <p>Wissen über Kriterien zur Beurteilung der Qualität von Datenquellen (z. B. Neutralität, Qualitätsstandards)</p> <p>Wissen, welche Charakteristika Daten aufgrund der Erhebungsmethode (Beobachtung, Messung, Befragung) besitzen</p> <p>Wissen, welche neuartigen Datenquellen durch die Digitalisierung entstehen („Big Data“)</p> <p>Wissen, welche Standards und Best Practices im jeweiligen Fachgebiet üblich sind, wenn Daten gesucht werden, z. B. ob mit Primärdaten oder Sekundärdaten gearbeitet wird</p>	<p>Fähigkeit, die für die Fragestellung geeigneten Daten zu suchen und auszuwählen</p> <p>Fähigkeit, Abfragen für Suchmaschinen und Datenbanken zu formulieren</p> <p>Fähigkeit, die Qualität von Datenquellen einzuschätzen</p> <p>Fähigkeit, eigenständige Erhebungen zu konzipieren, um sie selbst durchzuführen oder extern zu beauftragen</p>	<p>Bereitschaft, Entscheidungen hinsichtlich der zu beschaffenden Information zu treffen</p> <p>Bereitschaft, Informationsverluste im Prozess der Datenauswahl abzuwägen und zu akzeptieren</p> <p>Skeptische Grundhaltung bezüglich der Qualität von Datenquellen</p> <p>Offenheit gegenüber neuartigen Datenquellen (z. B. Sensordaten, App-Daten, etc.)</p>	<p>(1) Greift auf Datenportale zu, stellt Anfragen über Suchmaschinen, beauftragt einfache Erhebungen, aber Qualität der Quelle wird nicht zusätzlich geprüft</p> <p>(2) Nutzt Suchmaschinen, interne und externe Datenquellen für anspruchsvollere Anfragen, beauftragt anspruchsvolle Erhebungen und prüft die Qualität der Quellen</p> <p>(3) Greift auf Quellen zu, die durch komplexe Datenbankabfragen oder über Schnittstellen zu Maschinen, Apps usw. erreichbar sind, plant eigenständig anspruchsvolle Erhebungen und folgt jeweils einem standardisierten Qualitätssicherungsprozess</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
B.2.2: Daten integrieren	Liest Daten in verschiedenen Formaten automatisiert ein, integriert sie und dokumentiert die Integration	<p>Kenntnis der Datenmodelle und deren Beschreibung (Metadaten)</p> <p>Wissen, wie Daten zugänglich gemacht, gelagert und in vorhandene Infrastrukturen integriert werden können</p> <p>Wissen über Technologien zur (automatisierten) Beschaffung von Sekundärdaten und zur Lagerung</p> <p>Wissen über Methoden zur Erhebung von Primärdaten</p> <p>Wissen, welche Standards und Best Practices im jeweiligen Fachgebiet üblich sind, wenn Daten erhoben, beschafft und gelagert werden</p>	<p>Fähigkeit, geeignete Daten zu finden, zu beschaffen und zu integrieren</p> <p>Fähigkeit, Daten mit verschiedenen Methoden neu zu erheben</p> <p>Fähigkeit, geeignete Werkzeuge hierfür auszuwählen und zu benutzen</p>	<p>„Datenfairness“ als Grundhaltung</p> <p>Bereitschaft, Daten aktiv bereitzustellen, um den Informations- und Wissensgewinn für andere zu erleichtern</p> <p>Verständnis dafür, dass Datenbeschaffung stets subjektive Entscheidungen beinhalten, und Bereitschaft, diese Entscheidungen transparent zu machen und argumentativ zu rechtfertigen</p> <p>Bereitschaft, die Angemessenheit der zu sammelnden Daten für die Aufgabenerfüllung zu hinterfragen, d. h. die Effektivität der Arbeitsschritte sicherzustellen</p>	<p>(1) Einlesen gängiger Datensätze</p> <p>(2) Problembeseitigung zum korrekten Einlesen von Daten (Encoding usw.)</p> <p>(3) Automatisiertes Einlesen von Daten, automatisiertes Speichern in Datenbanken</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeich- zeichnung	Beschreibung	Beispiele für Wissen [„Knowledge“]	Beispiele für Fähigkeiten [„Skills“]	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
B.3.1: Daten verifi- zieren	<p>Prüft die Daten- qualität hinsicht- lich verschiede- ner Kriterien (Korrektheit, Relevanz, Reprä- sentativität, Vollständigkeit)</p> <p>Dokumentiert die Prüfung syste- matisch</p>	<p>Wissen über mögliche Qualitätsprobleme und Möglichkeiten, mit diesen umzugehen</p> <p>Wissen über mögliche Ursachen von Daten- qualitätsproblemen, die z.B. in der Erhe- bungsform, in Transformationen oder im Datenschutz begründet sind</p> <p>Wissen über Kriterien zur Bewertung von Datenqualität</p>	<p>Fähigkeit, Qualitätsprobleme, Fehler und Lücken in den Daten systematisch zu identifizieren und geeignet zu beheben</p>	<p>Objektivität als Grundhaltung, d. h. Daten nicht zu manipulieren, um eine bestimmte Aussage zu forcieren (z. B. bei der Festlegung von Ausreißern)</p> <p>Bereitschaft, Möglichkeiten und Grenzen der Interpretation der gesammelten Daten und ihrer eventuellen Transformationen aktiv zu durchden- ken und zu kommunizieren</p>	<p>(1) Falschen Typ von Variablen identifizieren (Text vs. numerisch)</p> <p>(2) Erkennen von stark korrelierten Daten, erste Behebung von inhaltli- chen Problematiken</p> <p>(3) Beseitigt Probleme in allen gängigen Bereichen und kann fehlende, neue Daten für eine Fragestellung beschaffen und diese sinnvoll an die bisherigen knüpfen</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeich- zeichnung	Beschreibung	Beispiele für Wissen [„Knowledge“]	Beispiele für Fähigkeiten [„Skills“]	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
B.3.2: Daten aufbe- reiten	Bereinigt Daten, korrigiert Fehler, imputiert fehlende Werte, standardisiert und transformiert Daten, filtert relevante Daten für eine jeweilige Fragestellung, verknüpft Daten	<p>Wissen über mögliche Technologien und Werkzeuge zum Transformieren von Daten</p> <p>Wissen über Datenformate und weitere Charakteristika von Daten (z. B. Skalenniveaus, Grad der Strukturiertheit)</p> <p>Wissen über Möglichkeiten, Daten zu transformieren, indem sie standardisiert oder verknüpft werden</p> <p>Wissen darüber, wie Transformationsprozesse den Informationsgehalt von Daten verändern</p>	<p>Fähigkeit, Daten z. B. durch Standardisierung, Recodierung, Aggregation, Kombination oder andere Verfahren zu transformieren</p> <p>Fähigkeit, verschiedene Datenquellen miteinander zu verknüpfen</p> <p>Fähigkeit, redundante Informationen in den Daten zu erkennen und Redundanzen zu beseitigen</p> <p>Fähigkeit, Daten zweckbezogen in verschiedenen Formen bzw. Aggregaten bereitzustellen</p> <p>Fähigkeit, zukünftige oder alternative Nutzungen der Daten vorauszusehen</p> <p>Fähigkeit, zukünftige oder alternative Interpretationen der Daten sowie ihrer Transformationen vorauszusehen</p>	<p>Bereitschaft, Zeit und Mühe in aufwändige und wenig spannende Aufbereitungsschritte zu investieren, um den relativen Wert der Daten zu erhöhen</p> <p>Verständnis für den Wert von Daten; Verstehen, dass Speicherplatz und Analysekapazitäten knappe Ressourcen darstellen und Bereitschaft, ressourcenschonend damit umzugehen, was z. B. Arbeitszeit und Energieverbrauch betrifft</p> <p>Zweckdienlichkeit und Nutzerorientierung als Grundhaltung, d. h. die Effektivität der Arbeitsschritte einzuhalten (z. B. bei der Imputation fehlender Werte)</p>	<p>(1) Einfache Erstellung neuer Variablen durch bereits vorhandene</p> <p>(2) Zusammenfügen von Datensätzen unter vorheriger Änderung von Ausprägungen</p> <p>(3) Komplexe Veränderungen von Datensätzen (Long- und Wideformat), komplexe Bearbeitung von Zeichenketten</p>

Tabelle 23: Kompetenzfeld B – Daten bereitstellen

C.3 Kompetenzfeld C: Daten auswerten – Von Daten zu Datenprodukten

Dies umfasst die Auswertung der Daten. Die erste Stufe bildet dabei die Analyse der Daten. Hier werden Analyseverfahren aus verschiedenen Gebieten (Statistik, Analytics, Machine Learning) unter Zuhilfenahme der geeigneten Werkzeuge sach- und zweckorientiert eingesetzt. In der zweiten Stufe werden die Daten analysiert. Hierbei werden statische und dynamische Visualisierungen zusammen mit passenden Werkzeugen genutzt. Die dritte Stufe umfasst die Verbalisierung von Daten. Dabei werden Datenanalysen in verschiedenen Textformen dargestellt und zur Kommunikation bereitgestellt

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
C.1: Daten analysieren	Setzt Analyseverfahren aus verschiedenen Gebieten (Statistik, Analytics, Machine Learning), unter Zuhilfenahme der geeigneten Werkzeuge sach- und zweckorientiert ein	<p>Kenntnis von Verfahren für unterschiedliche Aufgaben (Deskription, Exploration, Prognose) sowie über deren Voraussetzungen, Stärken und Schwächen</p> <p>Wissen über Verfahren für gerichtete und ungerichtete Fragestellungen</p> <p>Wissen über Schätzverfahren und Algorithmen</p> <p>Wissen über Möglichkeiten der Modelldiagnostik und der Modelloptimierung</p>	<p>Fähigkeit, messbare Beziehungen in Modellen abzubilden</p> <p>Fähigkeit, anhand der jeweiligen Fragestellung und der verfügbaren Daten geeignete Analyseverfahren zu identifizieren und auszuwählen</p> <p>Fähigkeit, das Modell geeignet zu spezifizieren (z. B. durch Festlegung von Optimierungskriterien)</p> <p>Fähigkeit, das Modell auf Schwächen und Artefakte (z.B. Overfitting, Multikollinearitätsprobleme) zu untersuchen und diesen</p>	<p>Bereitschaft, in einem iterativen und oft zeitaufwändigen Prozess Modelle zu implementieren und anzupassen</p> <p>Skeptische Grundhaltung bei der Datenanalyse</p> <p>Bereitschaft, Informationsverluste im Prozess der Analyse abzuwägen und zu akzeptieren</p> <p>Bereitschaft, „good analytics standards“ einzuhalten, selbst wenn diese nicht explizit definiert sind</p>	<p>[1] Kann mit grundlegenden statistischen Methoden wie etwa Mittelwert und Standardabweichung umgehen</p> <p>[2] Beherrscht und verwendet auch komplexere Modelle, kann einschätzen, welche Methoden für welche Fragestellungen und Daten sinnvolle Ergebnisse liefern und erkennt die Grenzen der Analyseergebnisse</p> <p>[3] Beherrscht und verwendet hochgradig komplexe Modelle und erkennt, wenn die Analyse keine sinnvollen Ergebnisse liefern kann bzw. wann die Informationen der Analyse keine Relevanz für die Fragestellung haben und der Analyseprozess</p>

<p>C.1: Daten analysieren</p>	<p>Setzt Analyseverfahren aus verschiedenen Gebieten (Statistik, Analytics, Machine Learning), unter Zuhilfenahme der geeigneten Werkzeuge sach- und zweckorientiert ein</p>	<p>Wissen über Maßnahmen, um die Robustheit und allgemeine Gültigkeit der Modelle sicherzustellen (z. B. Kreuzvalidierung)</p> <p>Wissen über mögliche Ursachen von Artefakten</p> <p>Wissen über Best Practices und Standards der Modellentwicklung und Datenanalyse, z. B. Validierung</p> <p>Wissen, dass bei der Analyse von Daten Information verloren geht und dass ein Auswahl- und Bewertungsprozess nötig ist, auf welche Information verzichtet werden kann</p>	<p>entgegenzuwirken</p> <p>Fähigkeit, die Unsicherheit der Modellergebnisse zu beurteilen und die benötigte Genauigkeit zu bestimmen</p> <p>Fähigkeit, zukünftige Nutzungen der Analyseergebnisse zu antizipieren</p> <p>Fähigkeit, relevante von irrelevanten Informationen im Analyseprozess zu trennen (z. B. Variablen zu selektieren)</p>	<p>Bereitschaft, ressourcenschonend zu arbeiten, z. B. das Modell nicht zu „over-engineeren“</p> <p>Bereitschaft, die benötigte Präzision auch bei knappen Ressourcen und gegen Widerstände durchzusetzen, um Trugschlüsse zu verhindern</p> <p>„Analytical Fairness“ als Grundhaltung, d. h. Bereitschaft, Analysen nicht durchzuführen, wenn das Risiko eines Missbrauchs hoch ist</p> <p>Objektivität als Grundhaltung, insbesondere in Situationen, in denen Datenlage und Fragestellung Spielraum für die Analyse lassen</p>	<p>beendet werden sollte</p>
-------------------------------	--	---	--	---	------------------------------

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
C.2: Daten visualisieren	Setzt statische und dynamische Visualisierungen unter Zuhilfenahme der geeigneten Werkzeuge sach- und zweckorientiert ein	<p>Kenntnis über die verschiedenen Diagramme, Diagrammtypen und deren Wirkung bei der Darstellung</p> <p>Kenntnis über die verschiedenen Darstellungsmöglichkeiten innerhalb der Diagramme (Farben etc.)</p> <p>Wissen, dass je nach Darstellungsweise verschiedene Schlussfolgerungen gezogen werden können</p>	<p>Fähigkeit, für den Datensatz die richtigen Diagramme und Darstellungsmöglichkeiten auszuwählen</p> <p>Fähigkeit, mögliche Unsicherheiten genau zu erkennen und zu minimieren</p> <p>Fähigkeit, Informationen im Datensatz genauso zu klassifizieren, dass sich die Wichtigkeit auch in der Darstellung wieder spiegelt</p> <p>Fähigkeit, eine Visualisierung so zu gestalten, dass genau das relevante Wissen übermittelt wird</p>	<p>Objektivität bei der Darstellung, keine bewusste Manipulation der Betrachtenden</p> <p>Bereitschaft, Zeit in eine aufwendigere Darstellung zu investieren, wenn diese zu richtigen Schlussfolgerungen führen</p> <p>Bereitschaft, auch Daten korrekt zu visualisieren, die nicht der eigenen Grundhaltung entsprechen</p>	<p>[1] Kann die grundlegenden Visualisierungen erstellen</p> <p>[2] Beherrscht eine Vielzahl von Visualisierungen und kann abschätzen, wann welche am besten geeignet ist</p> <p>[3] Beherrscht diverse Visualisierungen im Detail, kennt deren Stärken und Schwächen und erkennt auch schnell bei neuen Visualisierungen, welche Vor- und Nachteile sich dabei ergeben</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
C.3: Daten verbalisieren	Verbalisiert die Ergebnisse von Datenanalysen in verschiedenen Textformen sach- und zweckorientiert	<p>Kenntnis über das Fachvokabular in der Statistik und die feinen Unterschiede</p> <p>Wissen über die Methoden und deren Beschreibungen und Erklärungen</p>	Fähigkeit, die statistischen Ergebnisse so zu formulieren, dass sie auch von Nicht-Statistikfachleuten verstanden und interpretiert werden können, ohne dass es zu Fehlschlüssen kommt	<p>Bereitschaft, statistische Ergebnisse korrekt und objektiv zu präsentieren, sodass keine eventuell falsche oder verzerrte Schlussfolgerung nahegelegt wird</p> <p>Bereitschaft, auch Daten und Ergebnisse, die nicht der eigenen Grundhaltung entsprechen, objektiv darzustellen</p>	<p>(1) Kann einfache statistische Methoden beschreiben und erklären</p> <p>(2) Beherrscht das Beschreiben einer Vielfalt von statistischen Methoden und kann diese auch Laien erklären</p> <p>(3) Kann diverse statistische Methoden kurz und prägnant Personen ohne Fachkenntnisse beschreiben, sowohl schriftlich als auch mündlich, sodass der Analyseprozess verständlich ist</p>

Tabelle 24: Kompetenzfeld C – Daten auswerten:

C.4 Kompetenzfeld D: Datenprodukte interpretieren – Von Datenprodukten zu Daten

Dies umfasst die Interpretation der Datenprodukte. In der ersten Stufe werden zunächst Datenprodukte (Statistiken, Modellergebnisse) in zuvor verbalisierter Form interpretiert und die explizit bzw. implizit gelieferte Interpretation kritisch geprüft. In der zweiten Stufe werden dann Grafiken analysiert und Schlüsse auf wesentliche Elemente und Zusammenhänge gezogen. Auch hier wird die gelieferte Interpretation kritisch geprüft. In der dritten Stufe werden dann schließlich statistische Kennwerte und Modelle dahingehend interpretiert, dass Schlüsse auf zugrundeliegende Datenpunkte und Zusammenhänge gezogen und Prognosen durchgeführt werden können.

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
D.1: Daten-Analysen interpretieren	Interpretiert Datenprodukte (Statistiken, Modellergebnisse) in verbalisierter Form bzw. prüft kritisch die explizit oder implizit gelieferte Interpretation	<p>Wissen über statistische Kennzahlen wie Mittelwerte, Prozente, Prozentpunkte, deren Aussagekraft und Einschränkungen</p> <p>Wissen über Zusammenhänge zwischen statistischen Kennzahlen und den zugrundeliegenden Daten</p> <p>Wissen über den Bezug zwischen Kennzahlen (z. B. relative/absolute Häufigkeiten)</p> <p>Wissen, dass die Wahl einer bestimmten Kennzahl das Ergebnis eines bewussten Entscheidungsprozesses sein kann</p>	<p>Kann Schlüsse ziehen, über welche Charakteristika der Daten eine Kennzahl Aussagen trifft</p> <p>Versteht, welche Kennzahlen (auch verbalisiert) äquivalent verwendet werden</p> <p>Kann hinterfragen, ob spezielle Datensituationen das Ergebnis beeinflussen</p> <p>Kann hinterfragen, ob die Darstellungsform die Aussage eines Datenprodukts beeinflusst</p> <p>Kann hinterfragen, inwiefern die</p>	<p>Bereitschaft, explizit kommunizierte, vorgegebene Interpretationen in Daten-Verbalisierungen zu hinterfragen</p> <p>Bereitschaft, nach implizit kommunizierten Interpretationen zu suchen und diese zu hinterfragen</p> <p>Bereitschaft, das eigene Kontextwissen in Bezug auf dessen Einfluss auf die Interpretation zu hinterfragen</p> <p>Offenheit gegenüber neuen</p>	<p>(1) Kann einfache statistische Terminologie verstehen und deren Bezug zu den Daten interpretieren, kennt grundlegende Formen der Manipulation durch Statistiken und Berichte und die zu beachtenden Kriterien</p> <p>(2) Besitzt ein fortgeschrittenes Verständnis der Terminologie und kann zwischen verschiedenen Begriffen sauber differenzieren, kennt Bausteine expliziter Kommunikation und kann prüfen, ob explizite Interpretationen aus den Ergebnissen ableitbar sind</p> <p>(3) Besitzt ein vertieftes Verständnis der Terminologie, kann implizite Aussagen und Interpretationen erkennen, und zueinander sowie in Bezug auf den Sachverhalt abwägen und beurteilen</p>

<p>D.1: Daten-Analysen interpretieren</p>	<p>Interpretiert Datenprodukte (Statistiken, Modellergebnisse) in verbalisierter Form bzw. prüft kritisch die explizit oder implizit gelieferte Interpretation</p>	<p>Kenntnis statistischer Fachbegriffe Kenntnis statistischer Fehlschlüsse (z. B. Korrelation vs. Kausalität)</p> <p>Wissen, dass statistische Aussagen i. d .R. keine Einzelfallaussagen darstellen</p> <p>Wissen, dass die Interpretation das Hinzufügen von Kontextinformation erfordert</p>	<p>Interpretation der Ergebnisse vom eigenen Kontextwissen abhängt</p> <p>Kann hinterfragen, inwiefern die Darstellung der Ergebnisse durch die Wahl der Form (z. B. Prozente) oder die Verbalisierung die Interpretation manipulativ beeinflusst</p>	<p>Erkenntnissen, auch wenn diese den bisherigen Überzeugungen widersprechen</p> <p>Bereitschaft, die Bedeutung der Ergebnisse für den Sachverhalt, in den sie gestellt werden, zu hinterfragen</p>	
<p>D.2: Daten-Visualisierungen interpretieren</p>	<p>Interpretiert Grafiken und zieht Schlüsse auf wesentliche Elemente und Zusammenhänge bzw. prüft kritisch die explizit oder implizit gelieferte Interpretation</p>	<p>Wissen, welche Schlüsse aus Diagrammen gezogen werden können und welche nicht (Korrelation und Kausalität)</p> <p>Kenntnisse über die Vor- und Nachteile der einzelnen Diagramme</p>	<p>Fähigkeit, verschiedene und relevante Punkte in einem Diagramm zu erkennen und herauslesen zu können</p> <p>Fähigkeit, besondere Markierungen zu interpretieren</p> <p>Fähigkeit, Schlüsse von Modellgleichungen auf Datenpunkte zu ziehen</p> <p>Fähigkeit, die Aussagen und die Wahl der Visualisierung zu hinterfragen und kritisch einzuschätzen</p>	<p>Bereitschaft, die Visualisierung und die Schlussfolgerungen zu hinterfragen</p> <p>Bereitschaft, nach impliziert kommunizierten Informationen zu suchen und diese kritisch zu betrachten</p> <p>Offenheit gegenüber neuen Schlussfolgerungen und neuem Wissen, auch wenn dies dem momentanen Stand widerspricht</p>	<p>(1) Grundlegende Diagramme können interpretiert werden</p> <p>(2) Besitzt ein grundlegendes Verständnis der einfachen Diagramme und kann diese kritisch hinterfragen; zusätzlich können komplexere Visualisierungen interpretiert werden</p> <p>(3) Sowohl einfache als auch komplexe Diagramme können im Detail interpretiert und hinterfragt werden; sowohl implizit als auch explizit übermitteltes Wissen wird erkannt</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
D.3: Daten-Verbalisierungen interpretieren	Interpretiert statistische Kennwerte und Modelle dahingehend, dass Schlüsse auf zugrundeliegende Datenpunkte und Zusammenhänge gezogen oder Prognosen durchgeführt werden	Kenntnisse über die grundlegenden statistischen Methoden	Fähigkeit, den Analyseprozess aufgrund der Beschreibung zu verstehen und kritisch zu hinterfragen Fähigkeit, statistische Texte lesen und verstehen zu können	Bereitschaft, die Beschreibungen und Schlussfolgerungen zu hinterfragen Bereitschaft, implizit kommunizierte Informationen im Subtext zu suchen Bereitschaft, die Kommunikationsweise zu hinterfragen Offenheit gegenüber neuen Schlussfolgerungen und neuen Erkenntnissen, auch wenn diese dem momentanen Stand widersprechen	1) Kann einfachere Erklärungen von statistischen Methoden verstehen (2) Kann komplexere Analyseprozesse aufgrund von schriftlichen oder mündlichen Erklärungen verstehen und nachvollziehen (3) Kann komplexere Analyseprozesse aufgrund von schriftlichen oder mündlichen Erklärungen nachvollziehen und hinterfragen

Tabelle 25: Kompetenzfeld D – Datenprodukte interpretieren

C.5 Kompetenzfeld E: Daten interpretieren – Von Daten zu messbaren Objekten

Dies umfasst die Interpretation der Daten. In der ersten Stufe müssen dabei zunächst die Standardisierungen entschlüsselt werden, indem man verwendete statistische Methoden und damit die zugrundeliegende Transformation der Daten identifiziert. In der zweiten Stufe wird die Datenbeschaffung zurückverfolgt. Basierend auf der Analyse und den mitgelieferten Informationen kann dabei deren genaue ursprüngliche Beschaffung und Quelle identifiziert und deren Integrität beurteilt werden. Abschließend wird in der dritten Stufe das Datenkonzept rekonstruiert, indem Rückschlüsse zu der Datengrundlage sowie zu potentiellen Fehlschlüssen gezogen werden.

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
E.1: Standardisierung entschlüsseln	Verwendete statistische Methoden erkennen, einschätzen und interpretieren können; Erkennung der Transformation der Daten	Wissen über die verschiedenen statistischen Methoden, deren Ähnlichkeiten, Unterschiede und potentielle Interpretationen	<p>Fähigkeit, statistische Kennzahlen zu interpretieren und deren Verwendung zu hinterfragen</p> <p>Fähigkeit, statistische Kennzahlen und deren potenzielle Unterschiede objektiv zu interpretieren und sich nicht auf falsche Fährten locken zu lassen</p>	<p>Objektivität bei der Interpretation der Kennzahlen</p> <p>Offenheit, offensichtliche Schlussfolgerungen in Frage zu stellen</p>	<p>(1) Grundlegendes Verständnis der statistischen Kennzahlen, Datentransformationen und deren Definitionen</p> <p>(2) Detailliertes Verständnis der verschiedenen Transformationsmöglichkeiten und deren Unterscheidungen</p> <p>(3) Detailliertes Verständnis der Transformationen, deren Berechnungen sowie deren unterschiedliche Auswirkungen auf die Schlussfolgerungen</p>

Kompetenz		Kompetenzdimensionen			Kompetenzniveau
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
E.2: Daten-Beschaffung rückverfolgen	Basierend auf der Analyse und den mitgelieferten Informationen kann zurückverfolgt werden, wie die Daten beschafft wurden, aus welcher Quelle sie stammen und welches Vertrauen man den Daten schenken kann	<p>Kenntnis von potenziellen Datenquellen</p> <p>Inhaltliches Wissen über Qualität von bestimmten Datenquellen</p> <p>Wissen über mögliche Fehlerquellen bei der Datenbeschaffung und -erhebung</p>	<p>Fähigkeit, eine (systematische) Literaturrecherche durchzuführen</p> <p>Fähigkeit, Datenquellen und die Datenbeschaffung zu hinterfragen</p>	Objektivität bei der Interpretation und Einschätzung der Datenquellen	<p>(1) Suche eines einfachen Datensatzes (ggf. mit Link etc.)</p> <p>(2) Beschaffung von Informationen aus unterschiedlichen Quellen</p> <p>(3) Fähigkeit, diese Informationen geeignet zu kombinieren</p>
E.3: Daten-Konzept rekonstruieren	Rückschlüsse zur Datengrundlage sowie potentiellen Fehlschlüssen können gezogen werden	Kenntnisse über die theoretische Grundlage des Datensatzes und mögliche Fehlschlüsse, die zu falschen Interpretationen führen können	Fähigkeit, eventuelle Schwachstellen bei der Auswertung und der impliziten Informationsübermittlung zu erkennen	<p>Einstellung, die implizite Schlussfolgerung des Autors nicht sofort hinzunehmen, sondern zu hinterfragen</p> <p>Verständnis, dass Daten nicht alle Schlussfolgerungen erlauben, sondern dass auch Daten nicht alle Aussagen treffen können</p>	<p>(1) Grundlegende Datenkenntnisse, die bei der Interpretation der Daten helfen</p> <p>(2) Daten allgemein kritisch hinterfragen können bezüglich der Schlussfolgerungen</p> <p>(3) Detailliertes Wissen über den Datensatz, allgemeine Datengrundlagen und die Fähigkeit, Schlussfolgerungen aufgrund dieses Wissens in Frage zu stellen</p>

Tabelle 26: Kompetenzfeld E – Daten interpretieren

C.6 Kompetenzfeld F: Handeln ableiten – Von messbaren Objekten zum System

Dies umfasst die Ableitung von Handeln. In der ersten Stufe werden dabei zunächst konkrete Handlungsmöglichkeiten identifiziert, deren Einschätzung und Bewertung mit Daten ausgewertet werden kann. Außerdem wird eine Vorstellung vom möglichen Wertbeitrag der Daten bei der Ableitung von Handlungsmöglichkeiten entwickelt. In der zweiten Stufe beschreibt man die Integration von Ergebnissen in den Entscheidungsprozess und das auf den Ergebnissen basierende Handeln. In der dritten Stufe wird schließlich das datenbasierte Handeln auf seine Wirksamkeit geprüft und evaluiert.

Kompetenz		Kompetenzdimensionen			Kompetenzniveaus
Bezeichnung	Beschreibung	Beispiele für Wissen („Knowledge“)	Beispiele für Fähigkeiten („Skills“)	Beispiele für Haltung („Attitude“)	Beispiele für aufsteigende Niveaus
F.1: Handlungsmöglichkeiten identifizieren	Identifiziert konkrete Handlungsmöglichkeiten, deren Einschätzung und Bewertung mit Daten ausgewertet werden kann; besitzt eine Vorstellung vom möglichen Wertbeitrag der Daten bei der Ableitung von Handlungsmöglichkeiten	<p>Tiefes theoretisches und praktisches Fachwissen über das Anwendungsgebiet bzw. die Disziplin sowie ggf. verwandte Disziplinen</p> <p>Kenntnis der relevanten Literatur bzw. der beruflichen Anforderungen (Normen, Regeln, Qualitätsstandards, Prozessabläufe, Restriktionen)</p> <p>Wissen, dass und wie Daten und deren Analyse in der eigenen Disziplin zur Entscheidungsfindung dienen können</p>	<p>Fähigkeit, Handlungsmöglichkeiten, die datengetrieben aufgenommen sind aufgrund ihrer Sinnhaftigkeit einzuschätzen</p> <p>Fähigkeit, relevante von irrelevanten Informationen über die Handlungen zu trennen</p>	<p>Offenheit dafür, auch unerwartete Handlungsmöglichkeiten zu akzeptieren</p> <p>Wille, aus Daten zu lernen</p> <p>Bereitschaft, bestehende Regeln und Prozessabläufe zu hinterfragen</p>	<p>(1) Kann grundlegende Felder identifizieren, in denen datengetriebenes Handeln von Vorteil wäre</p> <p>(2) Kann genau einschätzen, in welchen Feldern datengetriebenes Handeln möglich wäre und wo dieses zu komplex wäre</p> <p>(3) Kann detailliert die Vor- und Nachteile von datengetriebenem Handeln einschätzen, die Möglichkeiten bewerten</p>

<p>F.2: Datengetriebenes handeln</p>	<p>Beschreibt Integrieren von Ergebnissen in den Entscheidungsprozess und das Basieren von Handeln auf diesen Ergebnissen</p>	<p>Tiefes theoretisches und praktisches Wissen zu den verschiedenen Handlungsmöglichkeiten und deren Implikationen</p> <p>Grundlegendes statistisches Wissen, um einzuschätzen, welche Analysen bei der Entscheidung wichtig sind</p>	<p>Fähigkeit, die passenden Analysen und Daten auszuwählen, um eine Entscheidung zur Handlung zu treffen</p> <p>Fähigkeit, die verschiedenen Handlungsmöglichkeiten so zu formulieren und quantifizieren, dass eine datengetriebene Entscheidung möglich ist</p> <p>Fähigkeit, die Analyseergebnisse so umzuwandeln, dass eine Handlung daraus abgeleitet werden kann</p> <p>Fähigkeit, die optimale Lösung zu identifizieren und potentielle unerwünschte Nebeneffekte zu erkennen</p>	<p>Bereitschaft, das Handeln auch auf datengetriebenen Entscheidungen zu basieren</p> <p>Offenheit, die Ergebnisse zu akzeptieren</p> <p>Bereitschaft, das momentane Handeln zu hinterfragen</p> <p>Objektivität bei der Analyse der Handlungsmöglichkeiten</p>	<p>(1) Grundlegende Handlungsentscheidungen können auf den Ergebnissen einer Analyse oder einer Statistik basiert werden</p> <p>(2) Auch komplexere Handlungsentscheidungen können quantifiziert und mit Daten begründet werden</p> <p>(3) Das Handeln ist komplett datengetrieben, es werden nicht nur Entscheidungen bezüglich des Handelns gefällt; das System ist laufend und die Handlungsstrategie wird je nach Daten angepasst</p>
<p>F.3: Wirkung evaluieren</p>	<p>Beschreibt die Auswertung des datenbasierten Handels aufgrund deren Wirksamkeit</p>	<p>Wissen über die Handlungsmöglichkeiten und deren Quantifizierung zum Wissen der Wirksamkeit</p>	<p>Fähigkeit, den Effekt, die Wirkung oder den Unterschied in Worte zu fassen und zu quantifizieren</p> <p>Fähigkeit, bei der Einschätzung der Wirkung auf die relevanten und wesentlichen Aspekte zu achten und sich nicht von unwichtigen Aspekten verwirren zu lassen</p>	<p>Objektivität bei der Einschätzung der Wirkung</p> <p>Offenheit den Ergebnissen gegenüber</p> <p>Bereitschaft, die Ergebnisse der Wirksamkeitseinschätzung auch tatsächlich umzusetzen</p>	<p>(1) Die grundlegende Wirkung von großen Handlungen und deren Unterschiede kann abgeschätzt werden</p> <p>(2) Die Wirksamkeit der datenbasierten Handlungen kann im Detail getestet werden</p> <p>(3) Die Wirksamkeit kann getestet werden und das Handeln kann, basierend auf den Ergebnissen, genau abgestimmt werden</p>

Tabelle 27: Kompetenzfeld F – Handeln ableiten

Literaturverzeichnis

Armstrong, P. (2010, Juni 10). Bloom's Taxonomy. Vanderbilt University. Zugriff am 31.12.2018.

Verfügbar unter: <https://wp0.vanderbilt.edu/cft/guides-sub-pages/blooms-taxonomy/>

Beile, P. (2008). Information Literacy Assessment: A Review of Objective and Interpretive Measures.

Berry, M. J. A. & Linoff, G. S. (2004). Data Mining Techniques. Wiley Publishing, Inc.

Carlson, J., Johnston, L., Westra, B. & Nichols, M. (2013). Developing an Approach for Data Management Education: A Report from the Data Information Literacy Project | International Journal of Digital Curation, 8 (1).

CAVORIT. (o. J.). Data Literacy Test. Zugriff am 14.11.2018. Verfügbar unter:

<http://www.dataliteracy.de/#test>

Cokely, E. T., Galesic, M., Schulz, E., Garcia-Retamero, R. & Ghazal, S. (2012). Measuring Risk Literacy: The Berlin Numeracy Test. Judgment and Decision Making, 7 (1), 23.

Data informed decision making cycle. (o. J.). . The Association of Independent Schools of New South Wales Limited. Verfügbar unter:

<https://www.aisnsw.edu.au/EducationalResearch/Documents/Infographics/Data%20Informed%20Decision%20Making%20Cycle%20-%20Infographic%202017.pdf>

Definition und Auswahl von Schlüsselkompetenzen. (2005). . OECD.

Der Europäische Qualifikationsrahmen für lebenslanges Lernen. (2008). . Europäische Kommission.

Zugriff am 12.12.2018. Verfügbar unter: https://ec.europa.eu/ploteus/sites/eac-eqf/files/leaflet_de.pdf

Deutscher Qualifikationsrahmen - DQR-Niveaus. (o. J.). . Zugriff am 19.11.2018. Verfügbar unter:

<https://www.dqr.de/content/2315.php>

Dichev, C. & Dicheva, D. (2017). Towards Data Science Literacy. Procedia Computer Science, 108, 2151–2160. Verfügbar unter: <https://doi.org/10.1016/j.procs.2017.05.240>

Drucker, P. F. (1963, Mai 1). Managing for Business Effectiveness. Harvard Business Review, (May 1963). Zugriff am 31.12.2018. Verfügbar unter: <https://hbr.org/1963/05/managing-for-business-effectiveness>

<https://hbr.org/1963/05/managing-for-business-effectiveness>

Erlinger, A. (2018). Outcomes Assessment in Undergraduate Information Literacy Instruction: A Systematic Review | Erlinger | College & Research Libraries. College & Research Libraries, 79 (4).

<https://doi.org/https://doi.org/10.5860/crl.79.4.442>

ESCO - Skills/competences - European Commission. [o. J.].. Zugriff am 31.12.2018. Verfüg-bar unter:

<https://ec.europa.eu/esco/portal/skill?uri=http%3A%2F%2Fdata.europa.eu%2Fesco%2Fskill%2F25a26ff6-af18-40b0-b2e2-cb58471015eb&conceptLanguage=en&full=true>

European e-Competence Framework 3.0. [2016]. . Europäische Kommission. Verfügbar unter:

http://www.ecompetences.eu/wp-content/uploads/2014/02/European-e-Competence-Framework-3.0_DE.pdf

Foucault, M. & Gordon, C. [1980]. Power/Knowledge : selected interviews and other writings, 1972-1977. New York: Pantheon Books.

Frauen in deutschen Vorständen bleiben Exoten. (2018, September 30). manager magazin. Zugriff am 8.1.2019. Verfügbar unter: <http://www.manager-magazin.de/unternehmen/karriere/frauen-in-deutschen-vorstaenden-bleiben-exoten-a-1230889.html>

GED Practice Questions | Free GED Practice Tests. [o. J.].. Zugriff am 13.11.2018. Verfüg-bar unter:

<https://www.gedpracticequestions.com/>

Goldhammer, F., Kröhne, U., Keßel, Y., Senkbeil, M. & Ihme, J. M. (2014). Diagnostik von ICT-Literacy: Multiple-Choice- vs. simulationsbasierte Aufgaben. Diagnostica, 60 (1), 10–21.

<https://doi.org/10.1026/0012-1924/a000113>

Goldsmith, S. & Crawford, S. [2014]. The Responsive City: Engaging Communities Through Data-Smart Governance. Jossey-Bass. Zugriff am 7.1.2019. Verfügbar unter: <https://www.wiley.com/en-us/The+Responsive+City%3A+Engaging+Communities+Through+Data+Smart+Governance-p-9781118910900>

Heidrich, D. J., Iese, F., Bauer, P., Iese, F. & Krupka, D. [2018]. Future Skills: Ansätze zur Vermittlung von Data Literacy in der Hochschulbildung. Hochschulforum Digitalisierung, 114.

Hemel, U. [2016]. Was heißt eigentlich digitale Fairness? Sieben Thesen. Institut für Sozial-strategie.

Zugriff am 8.1.2019. Verfügbar unter: <https://docplayer.org/38733608-Was-heisst-eigentlich-digitale-fairness-sieben-thesen.html>

Jenny, M. A., Keller, N. & Gigerenzer, G. [2018]. Assessing minimal medical statistical literacy using the Quick Risk Test: a prospective observational study in Germany. BMJ Open, 8 (8), e020847. Verfügbar unter: <https://doi.org/10.1136/bmjopen-2017-020847>

Kitchin, R. [2014]. The Data Revolution.

Kuhlen, R. [2013]. A 1 Information – Informationswissenschaft. In R. Kuhlen, W. Semar & D. Strauch (Hrsg.), Grundlagen der praktischen Information und Dokumentation (S. 1–24). Berlin, Boston: DE GRUYTER SAUR. Verfügbar unter: <https://doi.org/10.1515/9783110258264.xx>

Kuhn, S. D. med. [2018]. Data Literacy in der Medizin - welche Kompetenzen braucht ein Arzt? Hochschulforum Digitalisierung – Hochschulbildung im digitalen Zeitalter. Zugriff am 19.11.2018. Verfüg-

bar unter: <https://hochschulforumdigitalisierung.de/de/blog/data-literacy-medizin-welche-kompetenzen-braucht-ein-arzt>

Leichner, N., Peter, J., Mayer, A.-K. & Krampen, G. (2013). Assessing information literacy among German psychology students. *Reference Services Review*, 41 (4), 660–674. Verfügbar unter: <https://doi.org/10.1108/RSR-11-2012-0076>

Leichner, N., Peter, J., Mayer, A.-K. & Krampen, G. (2014). Assessing information literacy programmes using information search tasks. *Journal of Information Literacy*, 8 (1). Verfügbar unter: <https://doi.org/10.11645/8.1.1870>

Lohr, S. (2009, August 5). For Today's Graduate, Just One Word: Statistics. *The New York Times*.

Mandinach, E. B. & Gummer, E. S. (2013). A Systemic View of Implementing Data Literacy in Educator Preparation. *Educational Researcher*, 42 (1), 30–37. Verfügbar unter: <https://doi.org/10.3102/0013189X12459803>

Matthews, P. (2016). Data literacy conceptions, community capabilities, 11.

Motowidlo, S. J., Crook, A. E., Kell, H. J. & Naemi, B. (2009). Measuring Procedural Knowledge More Simply with a Single-Response Situational Judgment Test. *Journal of Business and Psychology*, 24 (3), 281–288. Verfügbar unter: <https://doi.org/10.1007/s10869-009-9106-4>

Münster, E. (2019, Januar 30). Hilfe, wieso versteht niemand meine Datenvisualisierung? Designation. Zugriff am 18.2.2019. Verfügbar unter: <https://www.designation.eu/2019/01/30/wieso-versteht-niemand-meine-datenvisualisierung/>

Nicholson, J., Gal, I. & Ridgway, J. (2018). Understanding Civic Statistics – a conceptual framework to aid teachers and lecturers, 22.

Oakleaf, M. (2009). Using rubrics to assess information literacy: An examination of methodology and interrater reliability. *Journal of the American Society for Information Science and Technology*, 60 (5), 969–983. Verfügbar unter: <https://doi.org/10.1002/asi.21030>

Qlik | Data Equality Campaign. [o. J.]. . Zugriff am 14.11.2018. Verfügbar unter: <http://dataequality.org/>

Quantitative Reasoning Section. [o. J.]. . Zugriff am 13.11.2018. Verfügbar unter: <https://www.mba.com/exams/gmat/about-the-gmat-exam/gmat-exam-structure/quantitative>

Ridsdale, C., Rothwell, J., Smit, M., Ali-Hassan, H., Bliemel, M., Irvine, D. et al. (2015). Strategies and Best Practices for Data Literacy Education: Knowledge Synthesis Report. Report. Verfügbar unter: <https://doi.org/info:doi/10.13140/RG.2.1.1922.5044>

Rosman, T., Mayer, A.-K. & Krampen, G. (2016). Measuring Psychology Students' Information-Seeking Skills in a Situational Judgment Test Format: Construction and Validation of the PIKE-P

Test. *European Journal of Psychological Assessment*, 32 (3), 220–229. Verfügbar unter:

<https://doi.org/10.1027/1015-5759/a000239>

Scharf, D., Elliot, N., Huey, H. A., Briller, V. & Joshi, K. (2007). Direct Assessment of Information Literacy using Writing Portfolios. *The Journal of Academic Librarianship*, 33 (4), 462–477. Verfügbar unter: <https://doi.org/10.1016/j.acalib.2007.03.005>

Schiold, M. (2004). Information Literacy, Statistical Literacy and Data Literacy. Gehalten auf der IASSIST QUARTERLY (IQ). Zugriff am 13.11.2018. Verfügbar unter:

<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.144.6309>

Schüller, K. & Busch, P. (2019a). Data Literacy: Ein Systematic Review zu Begriffsdefinition, Kompetenzrahmen und Testinstrumenten. *Hochschulforum Digitalisierung*, Arbeitspapier Nr. 46. DOI:

[10.5281/zenodo.3349865](https://doi.org/10.5281/zenodo.3349865)

Schüller, K. & Wrobel, C. (2018). Unlocking the Doors of Frankfurt Airport's Digital Market-place: How Fraport's Smart Data Lab Manages to Create Value from Data and to Change the Airport's Way of Thinking. In C. Linnhoff-Popien, R. Schneider & M. Zaddach (Hrsg.), *Digital Marketplaces Unleashed* (S. 637–649). Berlin, Heidelberg: Springer Berlin Heidelberg. Verfügbar unter:

https://doi.org/10.1007/978-3-662-49275-8_57

Seidl, T. P. D., Baumgartner, P. P. D., Brei, C., Gerdes, A., Lohse, A., Kuhn, S. P. D. med. et al. (2018). Diskussionspapier 3: (Wert-)Haltung als wichtiger Bestandteil der Entwicklung von 21st Century Skills an Hochschulen. *Hochschulforum für Digitalisierung*. Zugriff am 8.1.2019. Verfügbar unter:

<https://hochschulforumdigitalisierung.de/de/diskussionspapier-3-wert-haltung-als-wichtiger-bestandteil-der-entwicklung-von-21st-century-skills>

Swain, M. & Clarke, K. (2014). *The Information Literacy Test (ILT) Test Manual*, 13.

The Digital Competence Framework 2.0 - EU Science Hub - European Commission. (2018). EU Science Hub. Zugriff am 31.12.2018. Verfügbar unter: <https://ec.europa.eu/jrc/en/digcomp/digital-competence-framework>

The Kirkpatrick Model. (o. J.). . Zugriff am 12.12.2018. Verfügbar unter:

<https://www.kirkpatrickpartners.com/Our-Philosophy/The-Kirkpatrick-Model>

Treagust, D. F. (1988). Development and Use of Diagnostic Tests to Evaluate Students' Misconceptions in Science. *International Journal of Science Education*, 10 (2), 159–69.

Wallman, K. K. (1993). Enhancing Statistical Literacy: Enriching Our Society. *Journal of the American Statistical Association*, 88 (421), 1. Verfügbar unter: <https://doi.org/10.2307/2290686>

Watson, J. & Callingham, R. (2003). Statistical Literacy: A Complex Hierarchical Construct, 44.

Watson, J. & Callingham, R. (2004). Statistical Literacy: From Idiosyncratic to Critical Thinking, 47.

Watson, J. M. (1997). Assessing Statistical Thinking Using the Media. *The Assessment Challenge in Statistics Education*. Zugriff am 19.11.2018. Verfügbar unter: <http://ecite.utas.edu.au/10261>

Weinert, F. E. (2014). Leistungsmessungen in Schulen. Beltz.

Wild, C. (2012). The Concept of Distribution. SERJ EDITORIAL BOARD, 10.

Williford, C. & Henry, C. (2014). One Culture. Computationally Intensive Research in the Humanities and Social Sciences • CLIR. CLIR. Zugriff am 3.1.2019. Verfügbar unter:

<https://www.clir.org/pubs/reports/pub151/>

Impressum



Dieses Werk ist unter einer Creative Commons Lizenz vom Typ Namensnennung - Weitergabe unter gleichen Bedingungen 4.0 International zugänglich. Um eine Kopie dieser Lizenz einzusehen, konsultieren Sie <http://creativecommons.org/licenses/by-sa/4.0/>. Von dieser Lizenz ausgenommen sind Organisationslogos sowie falls gekennzeichnet einzelne Bilder und Visualisierungen.

ISSN (Online) 2365-7081; 4. Jahrgang

Zitierhinweis

Schüller, K., Busch, P., Hindinger, C. (2019). Future Skills: Ein Framework für Data Literacy – Kompetenzrahmen und Forschungsbericht. Arbeitspapier Nr. 47. Berlin: Hochschulforum Digitalisierung. DOI: [10.5281/zenodo.3349865](https://doi.org/10.5281/zenodo.3349865)

Herausgeber

Geschäftsstelle Hochschulforum Digitalisierung beim Stifterverband für die Deutsche Wissenschaft e.V.
Hauptstadtbüro • Pariser Platz 6 • 10117 Berlin • T 030 322982-520
info@hochschulforumdigitalisierung.de

Redaktion

Johanna Ebeling, Gino Krüger, Katharina Fischer, Andreas Sorge

Verlag

Edition Stifterverband – Verwaltungsgesellschaft für Wissenschaftspflege mbH
Barkhovenallee 1 • 45239 Essen • T 0201 8401-0 • mail@stifterverband.de

Layout

Satz: Gino Krüger, Till Rückwart
Vorlage: TAU GmbH • Köpenicker Straße 154 A • 10997 Berlin

Bilder

S. 8: unsplash / Raul Varzar, S. 14: unsplash / Guillaume Lssaly, S. 20: unsplash / Markus Spiske, S. 33: unsplash / Lerone Pieters, S. 41: unsplash / Shane Aldendorff, S. 47: unsplash / Matthew Henry

Illustrationen

Markus Armbruster - pictomind

Das Hochschulforum Digitalisierung ist ein gemeinsames Projekt des Stifterverbandes, des CHE Centrums für Hochschulentwicklung und der Hochschulrektorenkonferenz. Förderer ist das Bundesministerium für Bildung und Forschung.

www.hochschulforumdigitalisierung.de

The background is a solid blue color with a series of white, wavy, concentric lines that create a sense of depth and movement, resembling a stylized wave or a digital signal. The lines are most prominent on the right side and curve towards the center.

hochschulforumdigitalisierung.de/publikationen