6 | Output
6. Berufungsperiode

RatSWD.
Rat für Sozial- und
WirtschaftsDaten

Datenerhebung mit neuer Informationstechnologie

Empfehlungen zu Datenqualität und -management, Forschungsethik und Datenschutz

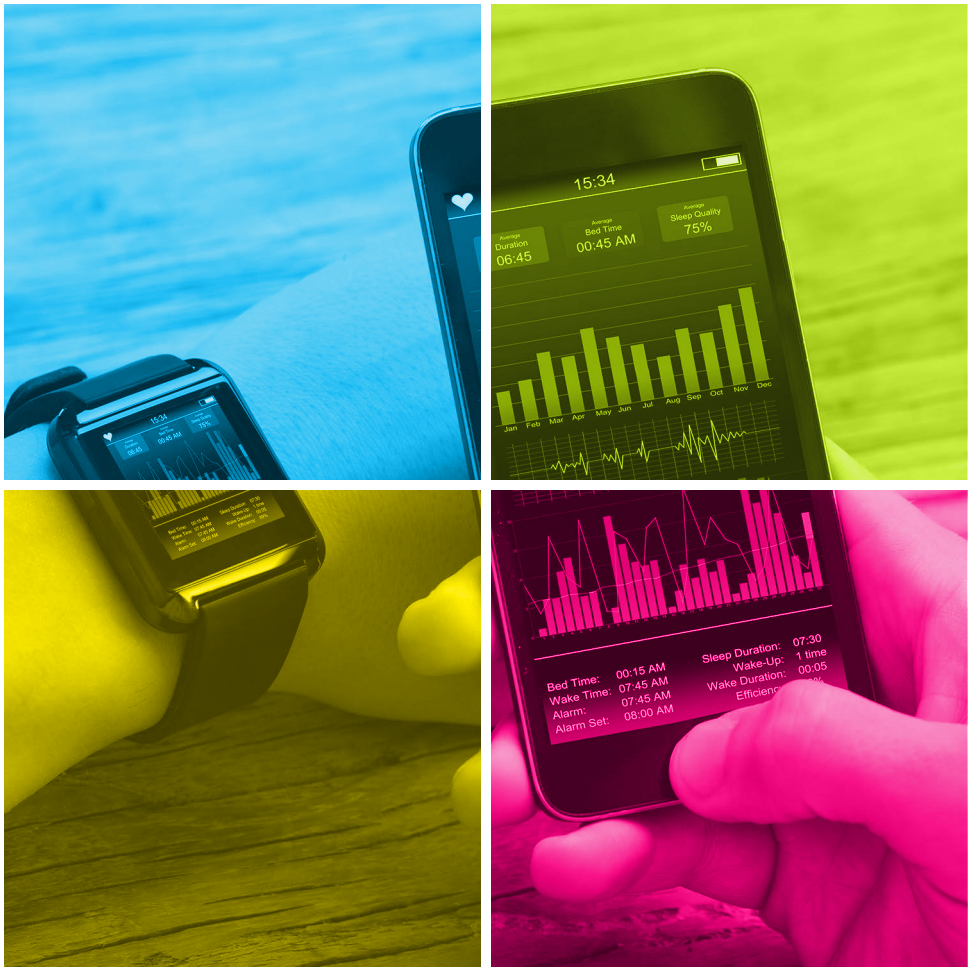

GEFÖRDERT VOM

Bundesministerium
für Bildung
und Forschung

Rat für Sozial- und Wirtschaftsdaten (RatSWD)

Datenerhebung mit neuer Informationstechnologie

Empfehlungen zu Datenqualität und -management, Forschungsethik und Datenschutz

Inhaltsverzeichnis

Executive Summary 6

1 Einleitung – Bedeutung der Datenerfassung mit neuer Informationstechnologie 7

2 Herausforderungen durch Datenerhebung mit neuer Informationstechnologie 10

2.1 Datenerhebung, Reliabilität und Validität. 11

2.2 Forschungsethik und Datenschutz 12

2.3 Datenmanagement 12

3 Güte von sensorenbasierten Erfassungsmethoden 13

3.1 Datenerhebung 13

3.2 Reliabilität 15

3.3 Validität 16

4 Forschungsethik und Datenschutz 21

4.1 Forschungsethische und datenschutzrechtliche Probleme 21

4.2 Informierte Einwilligung 26

5 Datenmanagement 31

5.1 Interoperabilität 31

5.2 Archivierung und Sicherung der Daten 31

6 Literaturverzeichnis. 33

Mitwirkende bei der Erstellung 38

Executive Summary

Die Datenerhebung mit neuer Informationstechnologie – also mit Smartphones, Wearables und anderen Sensoren – eröffnet der Wissenschaft ungeahnte Potenziale. Sensoren können Daten z. B. zu Aufenthaltsorten, Bewegungen, Geräuschen, Lichtverhältnissen, Medien-Nutzung, Video- und Sprachaufnahmen im Alltag und in Echtzeit erfassen. Wiederholte Datenerfassungen werden ebenso vereinfacht. Mit dieser Handreichung skizziert der Rat für Sozial- und Wirtschaftsdaten (RatSWD) eine qualitätssichernde Rahmung der Nutzung neuer Informationstechnologie in der Forschung.

Hauptaspekte des Berichts betreffen:

1) Güte von sensorengenerierten Daten

Forschende sollten beachten, dass die genutzten Sensoren meist als Konsum-Produkte konzipiert sind und die Datenqualität nicht per se wissenschaftlichen Anforderungen an Reliabilität und Validität entspricht. Forschende sollten darum den Datenerhebungsprozess, die Messgenauigkeit und die Validität ihrer Schlüsse kritisch prüfen und dokumentieren. Auch die Hersteller der Sensoren sollten für Transparenz über die Messgenauigkeit sorgen und die Datenverarbeitungsalgorithmen der Sensoren archivieren.

2) Forschungsethische und datenschutzrechtliche Fragen

Aufgrund der hohen zeitlichen und räumlichen Auflösung der meist personenbezogenen Daten, die mit neuer Informationstechnologie erhoben werden, sollten Forschende ein besonderes Augenmerk auf geeignete Maßnahmen zur Sicherung der Anonymität der Studienteilnehmenden legen. Dies betrifft z. B. Pseudonymisierungsstrategien, das Vergröbern von Daten, die Verzerrung von Stimmen und Standards zur Datensparsamkeit. Auch die Privatheit sollte sichergestellt werden (z. B. durch Möglichkeiten zum Editieren und Löschen von Daten durch die Teilnehmenden). Wenn Daten zu Drittpersonen anfallen oder illegales Verhalten von Studienteilnehmenden protokolliert wird, müssen Forschende einen angemessenen und rechtskonformen Umgang wahren. Teilnehmende (und Drittpersonen) sollten über den Zweck der Datenerhebung und die verbundenen Risiken, z. B. in den informierten Einwilligungen, aufgeklärt werden.

3) Datenmanagement

Da die neuen Erhebungsmethoden oft zu großen (Roh-)Datenvolumen mit sensitiven Informationen führen, stellen sich neue Herausforderungen bezüglich der Datenvorhaltung, -aufbereitung und -bereitstellung zur Sekundärnutzung und dem Management von Metadaten. Auch hier müssen die Anforderung des Datenschutzes und forschungsethische Standards mitgedacht und umgesetzt werden.

Der Bericht adressiert:

- Forschende und Studierende, die diese Methoden bereits nutzen oder zukünftig nutzen möchten,
- Ethikkommissionen und Forschungsfördernde bei der Beurteilung von entsprechenden Projekten und
- die interessierte Öffentlichkeit, Politik und Unternehmen, die neue Technologie (ggf. in Zusammenarbeit mit der Wissenschaft) nutzen.

1 Einleitung – Bedeutung der Datenerfassung mit neuer Informationstechnologie

Digitale Mobilität, Miniaturisierung und flächendeckende Nutzung durch die Bevölkerung prägen die Entwicklung neuer Informationstechnologie in den letzten Jahren. Diese Entwicklungen wirken sich auf die Erfassung von Forschungsdaten in den Sozial-, Verhaltens- und Wirtschaftswissenschaften aus. Ein Beispiel ist das **Experience Sampling**, z. B. durch die Selbsterfassung von Gedanken, Gefühlen, Verhaltensweisen und/oder Umgebungen im Laufe der Zeit mittels Smartphone-Fragebogen. Auch das **Mobile Sensing** wie beispielsweise die Erfassung von Ort, Bewegung, Geräuschen, Licht und Smartphone-Nutzung mittels Smartphone-Sensoren gehört zu diesen neuen Methoden. Zugenommen hat auch die Datenerfassung anhand von **Wearables**. Hierbei werden durch getragene Sensoren außerhalb von Smartphones physiologische Maße und Aktivitäten erfasst. Ebenfalls werden in die Umwelt integrierte Sensoren verwendet, um Bewegung, Ton, Bilder oder weitere Parameter zu erfassen (**Ambient Monitoring**).

Die Datenerfassung mit derartiger Informationstechnologie war in den Sozial-, Verhaltens- und Wirtschaftswissenschaften über Jahrzehnte ein Nischenthema (Fahrenberg und Myrtek 1996). Erst durch die Entwicklung des Smartphones haben diese Methoden der Datenerhebung sprunghaft zugenommen und werden in verschiedenen Bereichen der empirischen Forschung zunehmend eingesetzt (Harari et al. 2016; Yetisen et al. 2018). Diese Verfahren haben das Potenzial, die Forschung, aber auch die Anwendungspraxis (z. B. Diagnostik von Erleben und Verhalten im Alltag; Interventionen im Gesundheitsbereich) nachhaltig zu verändern, da solche Methoden zahlreiche Vorteile gegenüber bisherigen Erfassungsmethoden liefern.

Erstens erlauben diese Methoden die Erfassung von Merkmalen in Alltagssituationen („real life"). Im Vergleich zur klassischen Laborforschung bietet die Erfassung interessierender Phänomene im Alltag eine erhöhte ökologische Validität. Die Verallgemeinerbarkeit der Befunde auf den Alltag, d. h. den für Menschen häufigsten Kontext, wird so ermöglicht. Dies ist für die empirische Forschung von außerordentlicher Bedeutung, da viele bisherige Forschungsergebnisse nur mangelhaft übertragbar sind. Exemplarisch sei nur auf die sogenannte Praxis- oder Weißkittel-Hypertonie hingewiesen (Salles/Cardoso/Muxfeldt 2008; Stergiou et al. 2018). Diese bezieht sich auf das Phänomen, dass sich der Blutdruckwert nur durch die Situation der Messung in der ärztlichen Praxis erhöht und so zu unnötigen Verschreibungen blutdrucksenkender Präparate führen kann. Weiterhin ist der situative Kontext auch für viele Forschungsfragen relevant, da der Kontext das Verhalten von Individuen und Gruppen in vielfältiger Weise beeinflussen kann (Mischel und Shoda 1995). Mobile Sensorik erlaubt es, den Einfluss des Kontextes auf das Verhalten besser zu verstehen (z. B. über die Erfassung des Ortes, des sozialen oder physikalischen Umfeldes) (Böhmer et al. 2011).

Zweitens ist durch neue Informationstechnologie die Erfassung von Daten in Echtzeit („real time") möglich (Trull und Ebner-Priemer 2013). Relevante Episoden, d. h. flüchtige Ereignisse innerhalb eines größeren Geschehens, können anhand von objektiven Parametern, wie Bewegung oder Lokalisation, erkannt werden (je nach Fragestellung z. B. das Betreten eines Einkaufszentrums oder eines Wahllokals, die Nutzung öffentlicher Verkehrsmittel oder soziale Interaktionen). Auch spezifische Nachfragen in der Situation können durch das Smartphone automatisch und in Echtzeit in den jeweiligen Episoden versendet werden. Über die Datenerhebung in Echtzeit (z. B. die Verwendung von elektronischen Tagebüchern) lassen sich Gedächtniseffekte minimieren. Gedächtniseffekte beschreiben das Phänomen, dass Erinnerung ein aktiver Prozess ist, welcher systematischen Verzerrungen unterliegt (Schwarz 2012).

Ein dritter Vorteil der Datenerhebung mit neuer Informationstechnologie ist die objektive, multimodale Erfassung. So trägt die Entwicklung von Wearables zur objektiven Erhebung interessierender Merkmale in den Sozial-, Verhaltens- und Wirtschaftswissenschaften bei. Ein Beispiel ist die Messung körperlicher Bewegung über Beschleunigungssensoren. Einerseits ermöglicht die Miniaturisierung und massenhafte Verbreitung dieser Sensoren in Autos, Kameras etc. eine objektive und kostengünstige Datenerfassung. Andererseits erlauben sie eine präzisere Erfassung dieser Merkmale, welche mit subjektiven Erhebungsmethoden (z. B. Fragebogen) nicht möglich ist (Prince et al. 2008). Zudem lassen Wearables auch ein Langzeitmonitoring interessierender Merkmale zu.

Viertens sind durch die Nutzung von neuer Informationstechnologie wiederholte Datenerfassungen von Individuen möglich. Hierdurch können intraindividuelle Schwankungen, Veränderungen und Prozesse besonders gut erfasst werden. Vor allem in der Psychologie hat die Forschung zu intraindividuellen Prozessen in den letzten Jahren stark zugenommen (Diehl/Hooker/Sliwinski 2015) und die Datenerhebung mit neuer Informationstechnologie kann hier sehr vielversprechend eingesetzt werden.

Smartphones – ein allgemein verfügbares Instrument der technisch unterstützten Erhebung von Forschungsdaten

Smartphones sind mit einer Vielzahl von Sensoren ausgestattet, die im Forschungsbereich der Sozial-, Verhaltens- und Wirtschaftswissenschaften Anwendung finden können. Dazu zählen unter anderem:

Bei der Verwendung von Daten, die mit neuer Informationstechnologie erhoben wurden, entstehen für Forschungszwecke aber auch eine Reihe neuer Herausforderungen. Der vorliegende Bericht diskutiert im folgenden Kapitel zunächst die Herausforderungen, die bei der Datenerhebung mit neuer Informationstechnologie entstehen. Daraufhin leitet er Empfehlungen ab, wie die Güte von sensorenbasierten Erfassungsmethoden bestimmt und die Validität von Schlüssen aus den Daten überprüft und sichergestellt werden können. Weiterhin wird aufgezeigt, wie forschungsethische und datenschutzrechtliche Anforderungen bewältigt werden können und das Datenmanagement gestaltet werden kann.

Der Beitrag stellt somit eine erste Handreichung für Forschende und Studierende dar, welche neue Informationstechnologie in Forschungsprojekten bereits nutzen oder zukünftig nutzen möchten. Der Bericht soll zudem Hilfestellung für Ethikkommissionen und Forschungsfördernde bei der Beurteilung von entsprechenden Projekten leisten. Die Handreichung richtet sich schließlich an Zielgruppen außerhalb der (universitären) Forschung, wie die breite Öffentlichkeit, Politik und Start-Ups, die solche Technik (ggf. in Zusammenarbeit mit der Wissenschaft) nutzen.

Inhaltlich fokussiert der Beitrag auf die Erhebung von Daten einzelner Personen (individuelles Assessment) für wissenschaftliche Studien mittels mobiler Informationstechnologie wie Wearables, Smartphones und anderen mobilen Sensoren. Ebenfalls interessant, aber nicht Gegenstand des vorliegenden Beitrages, sind: 1) die Auswertungsmöglichkeiten solcher Daten (inkl. Big Data Technologie[1]), 2) virtuelle Realität, 3) Daten, die in Verbindung mit dem Internet of Things erhoben werden können, sowie 4) weitere Techniken zur Datenerhebung, bei denen Ähnlichkeit zu einer Laborsituation gegeben ist. Technische Aufnahmen von Video-, Bild- und Sprachdaten sind unabhängig von der hier behandelten neuen Informationstechnologie traditionell ein Hilfsmittel der qualitativ-interpretativen Sozialforschung. Dort steht nicht die technische Aufbereitung und Analyse der (inzwischen in der Regel digital vorliegenden) Text-, Video- und Bilddaten im Vordergrund, sondern deren hermeneutische und sonstige textinterpretative Analyse – meist integriert in komplexere Untersuchungsdesigns. An den wissenschaftlichen Nutzungsformen und Bearbeitungsweisen dieser Materialarten hat sich durch die zunehmende Nutzung neuer Aufnahmetechnologien (Smartphone statt Kassettenrecorder; Webcam statt VHS-Kassette) strukturell nichts geändert. In diesem in sich heterogenen Feld werden dem interpretativen Paradigma folgend Gütekriterien qualitativer Sozialforschung herangezogen (Strübing et al. 2018), die in diesem Output nicht behandelt werden.

1 Siehe hierzu RatSWD 2019.

2 Herausforderungen durch Datenerhebung mit neuer Informationstechnologie

Datenerhebung mit moderner Informationstechnologie eröffnet der empirischen Forschung neue Wege. Sie geht aber auch mit spezifischen Herausforderungen einher. Hier zu nennen sind die Datenerfassung, die Zuverlässigkeit der Merkmalserfassung (Reliabilität) sowie die Gültigkeit von Aussagen, die auf Basis der Daten getroffen werden (Validität). Darüber hinaus stellen sich spezifische Anforderungen durch Forschungsethik, Datenschutz und an das Datenmanagement.

Studien mit neuer Informationstechnologie: Exemplarische Ergebnisse und Herausforderungen

Beispiel 1:
Althoff et al. (2017) griffen mit „Mobile Sensing" auf die Beschleunigungswerte einer Schrittzähler-Smartphone-App bei über 700.000 Personen in über 100 Ländern zu (Anzahl der insgesamt erfassten Tage: 68 Millionen). Inhaltlich konnten die Autoren Aktivitätsunterschiede zwischen Ländern und deren Vorhersagewerte für Übergewicht aufzeigen. Methodisch beeindrucken die große Anzahl erfasster Personen und Tage sowie die Tatsache, dass auf einen bereits erhobenen Datensatz aus dem Konsumentenbereich zurückgegriffen werden konnte. Methodisch spannende Fragen ergeben sich zu Gütekriterien der genutzten Daten: Wurde das Smartphone die ganze Zeit am Körper getragen oder gab es Bewegungen, die es nicht erfasst hat, weil es z. B. den ganzen Tag auf dem Schreibtisch lag? Wie ist die Datenqualität? Lieferte die App Rohdaten oder aggregierte Schritte pro Tag, die durch einen unbekannten Algorithmus berechnet wurden? Darüber hinaus wirft die Studie forschungsethische und datenschutzrechtliche Fragen zum Datengebrauch auf: Dürfen Daten für Forschungszwecke genutzt werden, wenn zum Zeitpunkt der Datenerhebung solche Verwendungen (noch) nicht angedacht waren?

Beispiel 2:
Kontextabhängigkeit und Echtzeitanalysen werden in einer Studie von Tost et al. (2019) mit „Experience Sampling" demonstriert. Während Probanden für eine Woche ihren normalen Alltagsaktivitäten nachgingen, wurde der Kontext, in diesem Fall der Aufenthaltsort, über GPS in Echtzeit erfasst und löste ortsspezifische elektronische Tagebuchabfragen aus. Die Studie kam zu dem Ergebnis, dass sich die Probanden in der Nähe von Grünbereichen (z. B. Wäldern, Parks und größeren Grünstreifen) subjektiv wohler fühlten. Methodische und rechtliche Herausforderungen bei dieser Untersuchung sind z. B. die Berücksichtigung des Datenschutzes bei Lokalisationstracking und die Verfügbarmachung der Rohdaten zur Replikation.

Beispiel 3:
Brown et al. (2014) führten eine Untersuchung zu kognitiven Prozessen bei über 20.000 Teilnehmenden mit Hilfe einer Smartphone-App durch. Die App enthielt kurze Spiele, mit denen vier klassische Experimente repliziert werden sollten. Grundlegend war die Frage, inwieweit die per Smartphone-App durchgeführten Experimente zu ähnlichen Schlüssen führten wie vergleichbare Laborexperimente. Es konnte gezeigt werden, dass das Smartphone als Erhebungsinstrument funktioniert und dass durch diese Methode große Stichproben gewonnen werden können. Eine Herausforderung bei solchen Untersuchungen ist die Zuverlässigkeit der Messungen, da die Teilnehmenden die App ohne Aufsicht anwandten und unterschiedliche Hard- und Software nutzten. Darüber hinaus führten von 40.000 Personen, welche die App heruntergeladen hatten, ca. 20.000 Personen die kognitiven Tests nicht durch. Hier läge es nahe, die Gründe und Bedingungen für die mangelnde Teilnahmebereitschaft zu erforschen, um eventuelle Selektionsverzerrungen der Ergebnisse beurteilen zu können.

Beispiel 4:
Harari et al. (2019) nutzten Mobile Sensing, um Unterschiede in der Kontaktfreudigkeit (sociability) unter 926 jungen Erwachsenen zu vergleichen. Hierfür wurden Smartphone-Daten zu Konversationen wie Anrufe, SMS und Kommunikation in sozialen Medien genutzt und zu selbstberichteten Persönlichkeitsmerkmalen in Bezug gesetzt. Die Ergebnisse der Studie unterstützen frühere Schlüsse, dass Kontaktfreudigkeit zu einem relevanten Teil persönlichkeitsabhängig ist. Vorteilhaft durch die Erhebung mittels Smartphones ist das Vorliegen der Daten in Echtzeit. Kritisch zu prüfen wären Selektionseffekte, denn es wurden nur Daten von Studierenden erfasst, die ein bestimmtes Betriebssystem nutzten. Auch Ungenauigkeiten in der Messung von Gesprächen durch Tonaufnahmen sind möglich, denn die genutzte App konnte nicht zwischen Fernsehgeräuschen und echter Konversation der Teilnehmenden unterscheiden.

2.1 Datenerhebung, Reliabilität und Validität

Smartphones sowie Wearables und andere Sensoren wurden originär nicht für die Forschung im engeren Sinne, sondern als Konsum-Produkte entwickelt und optimiert. Untersuchungen zur Messgüte und zur Validität dieser Techniken wurden bisher nur selten durchgeführt (Peake/Kerr/Sullivan 2018; Shcherbina et al. 2017). Smartphones sowie die eingebauten Sensoren werden kontinuierlich weiterentwickelt und es werden Software-Updates durchgeführt, welche die Übertragbarkeit von Ergebnissen aus früheren Validierungsstudien in Frage stellen können. Inhalte solcher Veränderungen der Software bzw. die Algorithmen zur Gewinnung spezifischer Kennwerte werden von den Entwicklungsfirmen häufig nicht offengelegt (Evenson/Goto/Furberg 2015).

Die Datenerhebung mit mobiler Informationstechnologie zielt darauf ab, Aussagen über das Verhalten und Erleben von Personen in ihrem alltäglichen Leben („real life“) treffen zu können. Die technischen Voraussetzungen können dazu führen, dass spezifische Verzerrungen bei der Datenerhebung auftreten und so die Validität der Untersuchungsergebnisse einschränken. Beispielsweise kann eine Datenerhebung nicht zu jeder Zeit und an jedem Ort erfolgen, da Signale nicht empfangen werden (z. B. eingeschränkte GPS-Signale in Gebäuden oder keine Mikrofonaufnahme, wenn sich Geräte in der Tasche befinden; siehe Harari et al. 2019). Auch können Personen nicht zu jeder Zeit Informationen zur Verfügung stellen (z. B. Selbstberichtsdaten während der Steuerung eines Autos, beruflichen Sitzungen oder in Situationen, in denen die Privatheit gewahrt werden soll). Physiologische Messungen können zudem mehrdeutig sein und erfordern zu ihrer korrekten Interpretation meistens die zusätzliche Erfassung des situativen Kontextes, in dem die Messung stattgefunden hat (Schmidt et al. 2018). Unterschiedliche Kompetenzen der Untersuchungsteilnehmenden beim Umgang mit neuer Informationstechnologie können darüber hinaus zu Selektionseffekten in Bezug auf die untersuchten Personengruppen führen.

2.2 Forschungsethik und Datenschutz

Durch Sensoren lässt sich eine Vielzahl verschiedener Merkmale mit hoher zeitlicher und räumlicher Auflösung erfassen, die in manchen Kombinationen eine Identifikation einer erfassten Person mit hoher Wahrscheinlichkeit ermöglicht. Hierdurch ergeben sich eine Reihe forschungsethischer und datenschutzrechtlicher Fragen: Wie kann die Anonymität der untersuchten Personen gewahrt werden? Wie sollen Daten gespeichert werden, um die Gefahr einer Deanonymisierung auszuschließen? Wie können Personen selbstbestimmt darüber entscheiden, welche Daten sie zur Verfügung stellen und welche nicht? Welche Anforderungen ergeben sich aus der EU-Datenschutzgrundverordnung (DSGVO), insbesondere Art. 35 zur Datenschutz-Folgenabschätzung? Wie (ausführlich) soll eine informierte Einwilligung (informed consent) gestaltet werden, auch vor dem Hintergrund der Teilnahmebereitschaft? Welche Konsequenzen hat es, wenn strafrechtlich relevantes Verhalten aufgezeichnet wird?

Sprach- und Bildaufnahmen beziehen sich häufig nicht nur auf die Personen, die einer Untersuchung zugestimmt haben, sondern erheben darüber hinaus auch Daten von anderen Personen und Objekten. Hierdurch ergeben sich zusätzliche vielfältige forschungsethische und datenschutzrechtliche Herausforderungen: Dürfen Daten anwesender Personen erhoben werden oder müssen diese konkret über die Ziele der Studie aufgeklärt und ihre informierte Einwilligung eingeholt werden? Wie können die Privatheit und Anonymität anwesender Personen gewahrt werden?

2.3 Datenmanagement

Eingesetzte Sensoren liefern eine Vielzahl an Datenpunkten, die besondere Anforderungen an die Datenspeicherung und somit das Datenmanagement stellen können (z. B. Datenvorhaltung, -aufbereitung und -bereitstellung für Sekundärnutzung, Metadaten). Es ist darüber hinaus ein Paradigmenwechsel hin zu Open Science zu beobachten. Dadurch werden neue Forschungsansätze entwickelt, die darauf abzielen, Daten von Personen, die im Alltag z. B. durch Wearables oder Smartphones erhoben werden, freiwillig der Forschung über Internetplattformen zugänglich zu machen. Darüber hinaus werden zunehmend Daten für Reanalysen zur Verfügung gestellt. Damit verbunden sind Herausforderungen an die Sicherstellung der Privatheit von Daten bei der Speicherung und Bereitstellung u. a. in Repositorien von Forschungseinrichtungen und -datenzentren.

3 Güte von sensorenbasierten Erfassungsmethoden

■ Fragen und Empfehlungen, die sich auf die Güte von sensorenbasierten Erfassungsmethoden beziehen, werden im Folgenden in Bezug auf drei Aspekte behandelt: 1) Datenerhebung, 2) Reliabilität und 3) Validität. Die drei Aspekte sind teilweise miteinander verknüpft. Es werden daher gegenseitige Bezüge hergestellt.

3.1 Datenerhebung

Die Verwendung von Wearables und Smartphones in der wissenschaftlichen Forschung im Bereich der Sozial-, Verhaltens- und Wirtschaftswissenschaften steht der Herausforderung gegenüber, dass die meisten Soft- und Hardwareprodukte für den allgemeinen Konsum entwickelt werden. Wissenschaftliche Messgenauigkeit spielt dabei eine untergeordnete Rolle, wohingegen Design, Preis und Benutzungsfreundlichkeit primäre Anforderungen darstellen. Entsprechend finden sich im Konsumbereich Produkte, deren Nutzbarkeit für wissenschaftliche Zwecke fraglich ist. Zu nennen ist hier beispielsweise die mobile Erfassung der Herzfrequenzvariabilität.

Erfassung der Herzfrequenzvariabilität

Herzfrequenzvariabilität in einem bestimmten Frequenzbereich ist ein guter Indikator für die Aktivierung des Parasympathikus (eines Teils des Nervensystems). Zur Bestimmung werden die Millisekunden zwischen zwei aufeinanderfolgenden R-Zacken im EKG (Elektrokardiogramm) berechnet und diese Differenzen analysiert. Die R-Zacken sind die größten Zacken im EKG, welche die größte Erregung des Herzmuskels anzeigen. Konsum-Produkte hingegen nutzen die Pulswelle am Armgelenk über eine entsprechende Uhr oder ein Armband zur Abschätzung der Herzfrequenzvariabilität. Die Pulswelle ist – im Gegensatz zur R-Zacke des EKG – ein flach verlaufendes Signal, bei welchem der Gipfel einer Welle nur sehr ungenau zu bestimmen ist. Auch wird die Erfassung des pulsierenden Signals selbst von verschiedenen Einflüssen beeinträchtigt, z. B. von Sensorpositionsverschiebungen durch Arm- und Handbewegungen, Kontraktionen der Handmuskulatur, Veränderungen der Gefäßverengung (z. B. durch Kälte) oder venösem Rückfluss. Gerade bei der Erfassung von psychischem Stress und sportlicher Aktivität kommen diese Störeinflüsse stärker zum Tragen (Georgiou et al. 2018). Entsprechend ist eine im wissenschaftlichen Sinne messgenaue Erfassung der Herzfrequenzvariabilität über die Pulswelle physiologisch und technisch nicht möglich. Dennoch gibt es unzählige Produkte, die Herzfrequenzvariabilitätsmessungen anbieten. Eine Messgenauigkeit im wissenschaftlichen Sinne erfüllen diese Produkte zurzeit nicht.

Eine zweite Problematik liegt in der üblichen (Vor-)Verarbeitung der Rohdaten durch die Produkte. Unter Rohdaten werden die Primärdaten verstanden, die von einem Gerät unmittelbar erhoben werden und noch in keiner Weise weiterverarbeitet wurden. So werden bei einigen Konsum-Produkten, wie z. B. sog. Activitytrackern, die Rohdaten häufig gar nicht gespeichert, um Speicherplatz zu sparen. Zur Bestimmung abgeleiteter Merkmale (z. B. zurückgelegte Schritte) werden die hochaufgelösten Beschleunigungswerte über Algorithmen gefiltert, integriert und auf Minutenebene aggregiert. Von Sensorherstellern werden die entsprechenden Datenverarbeitungsmethoden wie z. B. der angewandte Algorithmus für abgeleitete Daten (z. B. zur Ortsbestimmung oder für den geschätzten Kalorienverbrauch) üblicherweise nicht veröffentlicht, da sie als Geschäftsgeheimnis gelten (Evenson/Goto/Furberg 2015). Entsprechend kann eine Beurteilung der Algorithmen kaum vorgenommen werden,

noch kann entschieden werden, ob bzw. unter welchen Bedingungen die Geräte bzw. Algorithmen korrekt arbeiten. Auch hier sei auf das Beispiel der Herzfrequenzvariabilität verwiesen. Brustgurte zur Erfassung des EKG aus dem Sportbereich glätten üblicherweise die Herzfrequenzkurve, um große, unwahrscheinliche Sprünge zu eliminieren. Nebenbei wird damit auch die gemessene Herzfrequenzvariabilität reduziert. Ist jedoch eine große Herzfrequenzvariabilität in einer wissenschaftlichen Studie von zentralem Interesse, so wird durch den Algorithmus die zentrale interessierende Variable verfälscht. Weiterhin kann unklar sein, welche Sensoren eines Wearables zur Bestimmung eines Merkmals verwendet werden. Häufig werden zur Berechnung von Merkmalen nicht nur ein Sensor, sondern mehrere Sensoren herangezogen. Unklar ist weiterhin, ob Episoden mit starker Bewegung automatisch bei der Berechnung der Herzfrequenzvariabilität ausgeschlossen werden, d. h. es ist nicht bekannt, ob die Werte des Beschleunigungssensors in der Signalverarbeitung des EKGs mitverarbeitet werden oder nicht.

Eine dritte Problematik von Konsum-Produkten sind die kurzen Produktzyklen von Hard- und Software. Konsum-Produkte sind selten länger als zwölf Monate auf dem Markt. Entsprechend sind die aktuellen Produkte meist nicht wissenschaftlich validiert. Regelmäßige Softwareupdates können zudem die Vergleichbarkeit einer Hardware über die Zeit innerhalb einer Studie zunichtemachen, insbesondere wenn die Messmethodik durch die Software verändert wird. Darüber hinaus versuchen Firmen die Batterielaufzeit ihrer Produkte zu verlängern, indem sie energieeffiziente Datenerhebungsstrategien und Algorithmen verwenden, d. h. bei Updates kann die Frequenz, mit der ein Merkmal erhoben wird (Samplingfrequenz), reduziert werden. Dies beeinträchtigt die Genauigkeit der Messungen. Auch eine Reduktion der Samplingfrequenz, abhängig von der noch vorhandenen Batterieleistung, ist denkbar, d. h. die Samplingfrequenz und damit die wissenschaftliche Messgenauigkeit wird bei niedrigem Akkustand vermindert.

Weiterhin existieren Geräte, welche die Samplingfrequenzen an das Stimulusmaterial anpassen. So zeichnet bspw. Google Clips (eine kleine tragbare Kamera) nur vordefinierte „interessante“ Situationen auf (z. B. Tiere und Kinder). Beim Einsatz ähnlicher Techniken in der Forschung ist es wichtig, transparent festzuhalten, nach welchen Kriterien die (automatisierte) Datenerhebung gesteuert wird, sofern dies überhaupt bekannt ist.

Die Dokumentation der Rahmenbedingungen während der Erhebung (z. B. genutztes Endgerät, verwendete Filter, Samplingrate, angewandte Algorithmen etc.) in einem Datenblatt ist daher essenziell (siehe auch Empfehlungen des Rates für Informationsinfrastrukturen (RfII 2019: 32, 84)). Dies gilt vor allem bei Daten, die von Sensoren zur Verfügung gestellt werden und sich auf unterschiedlichem Aggregationsniveau befinden, je nachdem, ob es sich um basale Rohdaten (ungefiltertes Beschleunigungssignal) oder abgeleitete Daten (z. B. Ortsbestimmung, Kalorienverbrauch) handelt. Von großer Bedeutung für die Interpretation und für das Verständnis der erhobenen Daten sind darüber hinaus Kontextinformationen (z. B. Beschreibungen [Annotationen] von Vorgängen und Aktivitäten bei der Erfassung von Bewegung zum Training und zur Evaluation von Algorithmen) (ebd.: 12). Eine detaillierte Dokumentation des Datenerhebungsprozesses ist auch notwendig, um eine Reanalyse derjenigen Daten zu ermöglichen, die in Repositorien zur Verfügung stehen.

Empfehlungen zur Datenerhebung

1) Datenerhebung erfordert eine umfassende **Dokumentation des Datenerhebungsprozesses**. Die Dokumentation bei Datenerhebung mit neuer Informationstechnologie sollte Informationen zu folgenden Aspekten umfassen:
   - Alle **verwendeten Sensoren und Softwares** (Hersteller, Typ, Herstellungsjahr, Softwareversion)
   - **Rohdaten**, die erhoben und gespeichert wurden
   - Einzelne **Schritte der Datenverarbeitung**, um zu abgeleiteten Merkmalen zu gelangen
   - **Kontextinformation** (z. B. Situation der Datenerhebung)

2) Wissenschaftlerinnen und Wissenschaftler sollten **abwägen, ob teurere wissenschaftstaugliche Produkte Konsum-Produkten vorzuziehen sind**. Die Erfassung von interessierenden Merkmalen ohne jeglichen Zugang zu den Rohdaten und ohne Kenntnisse über die im Produkt ablaufende Signalverarbeitung ist im Rahmen wissenschaftlicher Studien nur schwer zu rechtfertigen.
3) Sensordaten sollten möglichst als **Rohdaten in einem standardisierten Format** in ursprünglicher (nativer) Auflösung erfasst werden. Dabei empfiehlt es sich, verlustfreie Kompressionsarten zu benutzen.
4) Werden Sensordaten auf dem Gerät schon zu höherwertigen Informationen verarbeitet, sollte bekannt sein, auf welche Art und Weise dieses umgesetzt wird. Werden dazu **datenanalytische Verfahren**, wie z. B. maschinelle Lernverfahren, eingesetzt, sollten die Trainingsdaten und das jeweils verwendete Modell **bekannt** sein. Entsprechende Programmcodes und Programmversionen sollten zur Verfügung gestellt werden.
5) Hersteller sollten **Dokumentationen** aller von ihnen hergestellten Sensoren und Datenverarbeitungsalgorithmen **für alle Versionen der Sensoren archivieren**. Dies ist jedoch bei marktüblichen Konsum-Produkten nicht zu erwarten. Entsprechend sollten unbedingt bereits beim Kauf von Produkten die entsprechenden Datenblätter archiviert werden. Ebenso sollte versucht werden, Software- und Hardware-Updates zu protokollieren.

3.2 Reliabilität

Reliabilität bezieht sich auf die Zuverlässigkeit einer Messung und zeigt an, in welchem Ausmaß Messfehlereinflüsse wirksam werden. Damit ist die Reliabilität ein zentrales Gütekriterium für die Bewertung von Erfassungsmethoden (Eid und Schmidt 2014). Für die Entwicklung von Smartphones und Wearables ist Reliabilität, im Gegensatz zu Design, Kosten oder Benutzungsfreundlichkeit, ein nachrangiges Merkmal. Im Gegensatz zu Medizinprodukten kann nicht ungeprüft davon ausgegangen werden, dass das Wearable das interessierende Merkmal auch zuverlässig misst. Studien zur Genauigkeit, mit der ein Gerät misst, und zum Ausmaß des Messfehlereinflusses sind selten (Evenson/Goto/Furberg 2015; Shcherbina et al. 2017). Für die Bewertung von Untersuchungsergebnissen, aber auch für diagnostische Entscheidungen in Bezug auf Personen, ist das Wissen über die Zuverlässigkeit einer Messung jedoch von großer Bedeutung. Bewährte Verfahren der Reliabilitätsbestimmung lassen sich grundsätzlich auch auf Daten anwenden, die mit neuer Informationstechnologie erhoben wurden. Evenson/Goto/Furberg (2015) unterscheiden in diesem Zusammenhang zwischen „Interdevice-Reliability“ und „Intradevice-Reliability“. Die Interdevice-Reliabilität wird geprüft, indem verschiedene Geräte desselben Produktionstyps (desselben Herstellers) gleichzeitig getragen und die Übereinstimmung der Messungen bestimmt wird. So können z. B. mehrere Fitnessbänder gleichzeitig getragen oder mehrere Geräte zur Ortsbestimmung gleichzeitig angewandt werden, um die Konvergenz der Messungen zu prüfen. Dieses Verfahren entspricht der Paralleltestmethode zur Bestimmung der Reliabilität (Paralleltest-Reliabilität; Eid und Schmidt 2014). Die Bestimmung der Intradevice-Reliabilität basiert auf der Ermittlung der Messgüte anhand wiederholter Messungen mit demselben Gerät (Retestmethode; ebd.). Allerdings hat diese Methode bei Wearables ihre Grenzen, da bei der Erfassung dynamischer Prozesse im Alltag Schwankungen über die Zeit typischerweise nicht nur die (unsystematische) Fehlervarianz, sondern auch das interessierende Merkmal (systematische Schwankungen) repräsentieren. Die Bestimmung der Reliabilität anhand von Wiederholungsmessungen kann daher nicht anhand einfacher statistischer Verfahren, wie z. B. der Korrelation der Messungen, bestimmt werden, sondern setzt komplexere statistische Verfahren voraus. Evenson/Goto/Furberg (2015) zufolge wurden daher bspw. bei Aktivitätstrackern noch keine Untersuchungen zur Intradevice-Reliabilität vorgelegt.

Zu beachten ist, dass Audio-, Video- und Textdaten zur weiteren Verarbeitung häufig kodiert werden. Hierbei muss die Güte des Kodiersystems sichergestellt und überprüft werden, indem z. B. auf Maße der Beurteilungsübereinstimmung zurückgegriffen wird.

Empfehlungen zur Wahrung von Reliabilität

1) Informationen zur **Messgenauigkeit von Sensoren** sollten von Herstellern berichtet und in wissenschaftlichen Publikationen, in denen Sensordaten verwendet werden, **angegeben** werden.
2) In empirischen Anwendungen sollten **Maße der Messgenauigkeit** berichtet werden. Hierbei kann auf verschiedene Methoden (z. B. Paralleltestmethode, Retestmethode) zurückgegriffen werden.
3) Werden komplexe Daten (z. B. Audio-, Video-, Textdaten) z. B. durch Kodierverfahren reduziert, muss die **Güte der Reduktionsverfahren** (z. B. durch Interrater-Reliabilität bzw. Maße der Beurteilungsübereinstimmung) **dokumentiert** werden.

3.3 Validität

Die Validität bezieht sich auf die Gültigkeit der Schlüsse, die aus Daten gezogen werden können (Messick 1989). Validität liegt dann vor, wenn die Schlussfolgerungen aus den Daten korrekt sind. In der empirischen Forschung lassen sich verschiedene Facetten der Validität unterscheiden (AERA/APA/NCME 2014; Messick 1995; Rammstedt et al. 2014) (siehe Box unten). All diese Facetten spielen auch bei der Datenerhebung mit neuer Informationstechnologie eine Rolle und müssen berücksichtigt werden. Im Folgenden sollen besonders die spezifischen Anforderungen an die Validität im Vordergrund stehen, die sich bei Datenerhebung mit neuer Informationstechnologie ergeben. Dabei stehen insbesondere zwei Facetten der Validität im Fokus, und zwar die Konstruktvalidität sowie die externe Validität, wobei – untergeordnet – auch auf die interne Validität Bezug genommen wird.

Facetten der Validität, auf die in dem vorliegenden Bericht Bezug genommen wird

Die **Konstruktvalidität** bezieht sich auf die Frage, inwieweit die erhobenen Werte im Sinne des zu erfassenden Konstrukts interpretiert werden können (Messick 1995).

Externe Validität liegt vor, wenn die Schlussfolgerungen, die aus einer Untersuchung gezogen werden können, auch auf andere Orte, Personen, Situationen und Zeitpunkte übertragen und damit generalisiert werden können (z. B. Eid/Gollwitzer/Schmitt 2017). Eine wichtige Facette der externen Validität ist die **ökologische Validität**. Diese bezieht sich auf die Frage, ob von den Daten, die in empirischen Untersuchungen gewonnen werden, auf das tatsächliche Leben geschlossen werden kann.

Eine Untersuchung gilt als **intern valide**, wenn eine eindeutige Schlussfolgerung bezüglich der kausalen Beeinflussung der abhängigen Variable durch die unabhängige Variable möglich ist, d. h. wenn alle relevanten systematischen Störeinflüsse ausgeschlossen werden können (z. B. Eid/Gollwitzer/Schmitt 2017).

Ein Vorteil der Datenerhebung mit neuer Informationstechnologie besteht darin, dass Personen in ihrem alltäglichen Leben untersucht werden können. Im Gegensatz zur Forschung im Labor hat die Datenerhebung mit neuer Informationstechnologie im Alltag einerseits ein weitaus größeres Potenzial, die ökologische Validität sicherzustellen. Andererseits ergeben sich dadurch aber auch spezifische Bedrohungen anderer Facetten der Validität. Ein Beispiel: Die Aktivität zweier Personen wird über zwei Wochen hinweg mit einem Activitytracker erfasst. Person A hat einen höheren mittleren Aktivitätswert als Person B. Die Validität des Schlusses, dass Person A aktiver sei als Person B, kann aber durch mehrere Sachverhalte bedroht sein. Eine Bedrohung der Konstruktvalidität liegt dann vor, wenn wissenschaftlich nicht gesichert ist, dass die eingesetzten Activitytracker tatsächlich die körperliche Aktivität erfassen. Externe Validität ist bedroht, wenn die Personen die Aktivitätstracker über die zwei Wochen hinweg nicht dauerhaft getragen haben, sondern in bestimmten Situationen (bspw. beim Fußballspiel) abgelegt haben. Im Folgenden sollen spezifische Gefahren für die Konstruktvalidität und die externe Validität behandelt werden, die durch Datenerhebung mit neuer Informationstechnologie entstehen.

3.3.1. Konstruktvalidität

3.3.1.1 Qualität der Sensoren

Für die Beurteilung der Konstruktvalidität einer Messung spielt zunächst die Qualität der verwendeten Sensoren eine große Rolle. Sind die Geräte überhaupt in der Lage, physiologische Maße wie die Herzratenvariabilität zu erfassen? Für viele kommerziell vertriebene Wearables fehlen solche Validierungsstudien (Peake/Kerr/Sullivan 2018). So ist Shcherbina et al. (2017) zufolge bspw. weitgehend unbekannt, inwieweit kommerziell vertriebene Wearables eine valide Erfassung kardiovaskulärer Parameter (wie z. B. der Herzrate und ihrer Schwankungen) ermöglichen. Die Qualität von Sensoren kann in Validierungsstudien untersucht werden. Dazu werden die von Sensoren erhobenen Daten mit Daten verglichen, die mit Gold-Standard-Methoden erhoben wurden (z. B. durch physiologische Messungen in standardisierter Laborumgebung). Um ein Maß für die Akkuratheit der Messung, den sog. Fehlerwert, zu erhalten, kann die Differenz aus dem Sensor-Wert und dem Gold-Standard-Wert gebildet und an dem Gold-Standard-Wert relativiert werden (Shcherbina et al. 2017: 5):

$$\blacktriangleright\ \textbf{Fehler} = \frac{\textbf{(Sensor-Wert – Gold-Standard-Wert)}}{\textbf{Gold-Standard-Wert}}$$

Dieser Fehlerwert ist nicht frei von Messfehlereinflüssen und somit abhängig von der Reliabilität der Messungen (s. Abschnitt 3.2). Mittelt man solche Fehlerwerte jedoch über viele Messungen, wird der Einfluss von unsystematischen Messfehlern reduziert. Der resultierende mittlere Fehlerwert ist ein guter Indikator dafür, inwieweit Sensoren zu systematisch verzerrten Messungen des interessierenden Konstruktes führen. Hierbei wird vorausgesetzt, dass die Gold-Standard-Werte valide Ergebnisse liefern. Bisherige Validierungsstudien zeigen, dass Sensoren (Wearables) durchaus valide Messungen liefern können, wobei dies jedoch nicht für alle Produkte und alle interessierenden Konstrukte in gleicher Weise gilt (Evenson/Goto/Furberg 2015; Peake/Kerr/Sullivan 2018; Shcherbina et al. 2017). So ist bspw. die Validität der Messung des Energieverbrauchs mittels kommerziell vertriebener Armbänder fraglich, während die Messung der Herzrate zuverlässiger ist (Schcherbina et al. 2017). Qualitätsstudien zur Sicherstellung der Konstruktvalidität sind daher unabdingbar. Aufgrund der kontinuierlichen Weiterentwicklung von Geräten müssen solche Qualitätsstudien kontinuierlich durchgeführt und ihre Ergebnisse publiziert werden. Zudem muss bei einem wissenschaftlichen Einsatz solcher Geräte ihre Akkuratheit nachgewiesen sein.

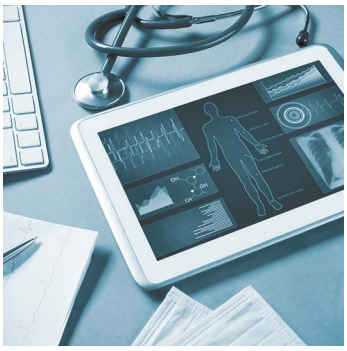

Daten, die mit Hilfe von Sensoren gewonnen werden, können mehrdeutig sein. So ist bspw. für die Interpretation von Maßen der Herzrate von Bedeutung, ob Bewegungsdaten angemessen berücksichtigt wurden. Faktoren wie die Körperhaltung, tageszeitliche Einflüsse (zirkadiane Effekte), Temperatur und Verhalten (z. B. Essen, Trinken, Rauchen) können darüber hinaus die Messung beeinflussen und die Validität gefährden. Von besonderer Bedeutung ist, dass der Einfluss solcher Störfaktoren häufig um ein Vielfaches höher ist als die interessierenden Effekte selbst, wenn durch geplante Interventionen Einfluss genommen wird. So sind z. B. Erhöhungen der Herzfrequenz um 20 Schläge durch Positionsveränderung (Aufstehen) oder Bewegung normal. Effekte dieser Größe (20 Schläge) werden durch psychologische Manipulationen zumeist nicht erreicht. Sind diese Störvariablen unsystematisch und hängen nicht mit der Intervention zusammen, wird hierdurch nur die Präzision der Messung des Effekts verringert. Sind diese Störvariablen jedoch systematisch und hängen mit der Intervention zusammen, wird eine weitere Facette der Validität, die interne Validität, bedroht. Die Veränderung der Herzfrequenz ist dann möglicherweise nicht auf die Intervention, sondern auf die Störfaktoren zurückzuführen. Zur Sicherung der Validität ist daher bei der Erfassung der Herzfrequenz als verhaltenswissenschaftlichem Maß die Kontrolle von Bewegung und Körperlage unerlässlich (Houtveen und de Geus 2009). Zur Überprüfung der Konstruktvalidität bietet sich ein multimethodales Vorgehen an. So kann z. B. die Validität von Schlüssen auf Aktivitäten des Nervensystems dadurch überprüft werden, dass die Konvergenz anderer Informationsquellen (z. B. Katecholamine im Urin, proportionaler Pulsdruck und Hautleitfähigkeit) nachgewiesen wird.

Die Berücksichtigung der Rahmenbedingungen ist nicht nur für Verfahren von Bedeutung, die Herz-Kreislauf-Merkmale erfassen. Auch Bewegungsdaten können nur angemessen interpretiert werden, wenn der situative Kontext während der Datenerfassung mit erhoben wird (Schmidt et al. 2018). Dies kann beispielsweise durch Befragungen oder Beobachtungen geschehen.

3.3.1.2 Qualitätssicherung bei der Weiterverarbeitung von Rohdaten durch Algorithmen

Häufig werden die Rohdaten verschiedener Sensoren anhand von Algorithmen weiterverarbeitet, um ein interessierendes Konstrukt zu erfassen. Um bspw. Messwerte für Bewegung zu generieren, werden die Informationen von Beschleunigungssensoren und der Drehbewegung (gemessen durch Gyroskope) durch Algorithmen verarbeitet (Klucken et al. 2019). Ob diese Algorithmen korrekt arbeiten, muss in sog. technischen Validierungsstudien nachgewiesen werden (ebd.).

Auch bei der Erhebung von Audio- und Bilddaten werden Algorithmen eingesetzt. Die Interpretation der Daten basiert zumeist auf diesen maschinell erzeugten Daten. Um die Validität solcher Daten abschätzen und sicherstellen zu können, müssen diese mit realen Beobachtungen („ground truth") abgeglichen werden. So kann bspw. bei Audioaufzeichnungen, bei denen Signale automatisiert auf dem Gerät verarbeitet werden (sog. Behavioral Signal Processing; Narayanan und Georgiou 2013), die Güte maschineller Verhaltensbestimmung für einen Teil der untersuchten Personen mit Handkodierungen auf der Basis von Aufzeichnungen des rohen Audiosignals abgeglichen werden. Wenn in einer Studie kein rohes Audiosignal gespeichert wurde oder werden kann, kann die Präzision des Verhaltensbestimmungsalgorithmus gegen Handkodierung in einer Pilotstudie mit roher Audioaufzeichnung (im beschränkten Kontext und mit Zustimmung aller Beteiligten, aber unter realistischen Bedingungen) abgeglichen werden. Werden Rohdaten kodiert, so kann in Validierungsstudien auch die Übereinstimmung von Kodierungen untersucht werden.

3.3.2 Externe Validität

Die externe Validität in Studien mit neuer Informationstechnologie ist vor allem durch Selektionseffekte in Bezug auf die erfassten Situationen und untersuchten Personen sowie durch Reaktivitätseffekte bedroht.

3.3.2.1 Selektionseffekte: Situationen

Datenerhebung mit neuer Informationstechnologie bietet den Vorteil, dass Daten in der natürlichen Lebenswelt erfasst werden und so ökologische Validität sichergestellt werden kann (Harari et al. 2019). Allerdings kann die ökologische Validität dadurch bedroht werden, dass in bestimmten Lebenssituationen keine Daten erhoben werden können (z. B. können keine Smartphone-Befragungen während der Steuerung eines Autos durchgeführt werden, da sich die Teilnehmenden durch die Beantwortung strafbar machen würden). Zudem besteht die Möglichkeit, dass die Teilnehmenden in bestimmten Situationen keine Fragen per Smartphone beantworten wollen oder Wearables tragen möchten (Brown/Blake/Sherman 2017). Außerdem erlauben bestimmte Umwelten keine Datenerfassung (z. B. GPS-Daten in der U-Bahn oder in Gebäuden; Mikrofonaufnahmen, wenn das Aufnahmegerät in der Tasche liegt). Falls selektiv in bestimmten Situationen keine Daten erhoben werden (z. B. während Konflikten, weil ggf. ein Privacy-Button am Aufnahmegerät aktiviert wurde), ist die Repräsentativität der Verhaltensstichprobe nicht mehr gegeben und somit sind die Ergebnisse nicht auf weitere Situationen generalisierbar.

3.3.2.2 Selektionseffekte: Personen

Die Anwendung neuer Informationstechnologie setzt von Studienteilnehmenden spezifische Fähigkeiten (z. B. Kenntnisse zur Bedienung eines Smartphones) voraus. Hierdurch kann es zu Verzerrungen von Stichproben kommen, die dokumentiert werden sollten (z. B. Ausschöpfungsquote, Erhebung von Ablehnungsgründen). Fraglich bleibt dabei, inwieweit die Ergebnisse auf andere Populationen übertragen werden können. Die Befürchtung jedoch, dass an solchen Studien nur junge, männliche Personen mit hoher technischer Affinität teilnehmen, wurde durch Studien im Bereich der Alternsforschung eindeutig widerlegt (Brose und Ebner-Priemer 2015). Die Validität der Ergebnisse ist darüber hinaus bedroht, wenn Geräte (z. B. Smartphones, Fitness-Tracker etc.) mit anderen Personen geteilt oder – im Extremfall – (ausschließlich) von anderen als der für die Studie ausgewählten Person verwendet werden.

3.3.2.3 Reaktivitätseffekte

Der Schluss auf das Verhalten im Alltag kann auch dadurch gefährdet werden, dass durch das Wissen über die Datenerhebung Reaktivitätseffekte hervorgerufen werden (Brown/Blake/Sherman 2017). Personen können während der Datenerhebung bestimmtes (sozial) erwünschtes Verhalten zeigen, indem sie bspw. mehr Sport treiben als gewöhnlich. Gleiches gilt für (sozial) unerwünschtes Verhalten, welches während der Studienteilnahme bewusst unterlassen wird und so die Validität der Ergebnisse einschränkt. Bisherige empirische Studien zu Reaktivitätseffekten weisen darauf hin, dass diese weitgehend unbedenklich sind (Stone et al. 2003). Zwar sind die Möglichkeiten begrenzt, Reaktivitätseffekte auszuschließen, sie nehmen aber je nach Untersuchungsdesign nach einigen Stunden oder Tagen deutlich ab. Empfehlenswert ist daher, die ersten Messungen separat zu analysieren (Shrout et al. 2018). Bislang existieren keine konkreten Empfehlungen, welcher Anfangszeitraum getrennt betrachtet werden soll. Dieser kann zudem je nach Sensor bzw. Forschungsinteresse und Erhebungsmethode unterschiedlich sein (Clemes und Deans 2012). Darüber hinaus ist zu beachten, dass andere Datenerhebungsmethoden als Vergleichsstandard herangezogen werden sollten. So ist der Effekt von sozialer Erwünschtheit bei Befragungen gravierender als bei einer Datenerhebung, die direkt im Alltag der Teilnehmenden stattfindet.

Empfehlungen zur Beurteilung der Validität

Konstruktvalidität

1) Für Sensoren, die in wissenschaftlichen Studien eingesetzt werden, sollte anhand von Validierungsstudien die **Konvergenz mit Gold-Standard-Methoden** nachgewiesen werden.

2) Durch Sensoren gewonnene Ergebnisse sollten in **theoriegeleiteten Validierungsstudien** (u. a. mit Rückgriff auf andere Datenquellen wie z. B. Verhaltensbeobachtungen und Befragungen) auf ihre Gültigkeit überprüft werden.

3) Bei mehrdeutigen Signalen sollten – soweit dies mit forschungsethischen und datenschutzrechtlichen Standards zu vereinbaren ist (siehe Kapitel 4) – durch die Hinzunahme weiterer Methoden sowie der Erfassung des Kontextes der Datenerhebung die **Gültigkeit der Schlüsse** nachgewiesen werden. Dies betrifft in besonderem Maße die Erhebung von physiologischen Prozessen im Alltag.

4) Werden Daten anhand von Algorithmen generiert oder ausgewertet, sollte in technischen Validierungsstudien die **Korrektheit der Algorithmen** aufgezeigt werden. Zudem sollten diese Daten mit realen Daten („ground truth“) abgeglichen werden. Sofern möglich, sollte dieser Abgleich im Rahmen jeder Datenerhebung (anhand von Teilstichproben) durchgeführt und dokumentiert werden. Ist dies in realen Anwendungen nicht möglich, sollte dies zumindest in Pilotstudien erfolgt sein.

Externe Validität

5) **Datenausfälle durch selektive Situationsstichproben** müssen dokumentiert und – sofern möglich und sinnvoll – anhand geeigneter Methoden rekonstruiert und korrigiert werden. Hierzu bieten sich verschiedene Vorgehensweisen an:

a) Eine **nachträgliche Befragung der Probanden** (z. B. auch anhand entsprechend implementierter Fragen auf dem Smartphone) kann Aufschluss über die Gründe fehlender Daten geben und gegebenenfalls ermöglichen, fehlende Daten zu rekonstruieren. Eine derartige Befragung kann jedoch von den Befragten negativ bewertet werden.

b) Eine Abschätzung der Selektivität der erfassten Situationen ist eventuell über einen **Vergleich** der Auftretenshäufigkeiten dieser Situationen in Datensätzen möglich, die **mit unterschiedlichen Methoden** erhoben wurden (Mobile Sensing, Experience Sampling, Feldbeobachtung, Fragebogen). Studien, die dies systematisch vornehmen, sind zwar extrem selten, jedoch finden sich Beispiele in der Forschung zu illegalen Rauschmitteln (Linas et al. 2016).

c) Falls durchführbar (abhängig von der Belastung der Teilnehmenden und den vorhandenen Ressourcen) kann der **Erhebungszeitraum verlängert** oder die **Erhebungshäufigkeit erhöht** werden. So könnten z. B. bei kurz andauernden Situationen alle 60, 30 oder 15 Minuten Daten erhoben werden. Auch können Maße der Akzeptanz bzw. Belästigung erhoben werden, um deren Einfluss auf die Befolgung der Datenerhebungsanweisungen (engl. Compliance) abzuschätzen. Generell dürfte eine hohe Compliance durch solche Verfahren erreicht werden (Trull und Ebner-Priemer 2013). Systematische Studien hierzu sind jedoch noch sehr selten (Stone et al. 2003).

d) Um das Ausmaß fehlender Daten abzuschätzen, kann erfasst werden, **wie häufig** Teilnehmende Möglichkeiten der **Editierung und Zensierung** ihrer Daten genutzt haben.

e) Durch entsprechende **Incentivierung** (z. B. Teilnahmehonorar) kann versucht werden, die Compliance zu erhöhen (Göritz 2014).

6) **Datenausfälle** durch **selektive Personenstichproben müssen dokumentiert** und – sofern möglich und sinnvoll – anhand geeigneter Methoden **rekonstruiert und korrigiert werden**. Hierzu kann auf verschiedene Ansätze, u. a. aus der Surveyforschung (Kreuter et al. 2018; Schupp und Wolf 2015), zurückgegriffen werden:

a) Um die Selektivität der Teilnehmenden analysieren und durch statistische Verfahren (z. B. Gewichtung) korrigieren zu können, kann es, wie in Kausalanalysen üblich, hilfreich sein, die **Teilnehmenden aus Datenquellen (zufällig) auszuwählen**, die relevante Informationen über alle Teilnehmenden und Nichtteilnehmenden enthalten. Dies können entweder administrative Daten wie Bevölkerungsregister sein oder aber bestehende repräsentative Surveys. Der Vorteil der Stichprobenziehung aus Surveys (vgl. Kreuter et al. 2018) ist, dass dort Fragen eingebracht werden können, die wichtige Zielvariablen der späteren Erhebung mit neuer Technologie vorwegnehmen, wie z. B. deren Nutzungsintensität oder Variablen, die mithilfe der neuen Technologie gemessen werden sollen. Es lässt sich dann modellieren, ob die Teilnehmenden der Studie bei den zentralen Maßen der Studie von Nichtteilnehmenden abweichen.

b) Daten von Teilnehmenden (und ggf. der Kontrollgruppe) können **mit externen Datenquellen oder Statistiken verglichen** werden.

c) Daten von Teilnehmenden und Nichtteilnehmenden können **mit kleinräumigen kommerziellen Daten** (z. B. infas 360) **verknüpft** werden (im Surveykontext vgl. Sinibaldi/Trappmann/Kreuter 2014).

d) Nichtteilnehmende können zu **Gründen der Nicht-Teilnahme befragt** werden.

e) Wird die Rekrutierung für die Studie persönlich durchgeführt, so besteht die Möglichkeit, dass Recruiter **Informationen zu Teilnehmenden und Nichtteilnehmenden beobachten bzw. schätzen** (vgl. West 2013).

f) Es muss erfasst werden, ob und in welchem Umfang Geräte (z. B. Smartphones, Fitness-Tracker etc.) mit anderen Personen geteilt werden. Hierzu bietet sich an:

- Die **Einwilligungserklärung** für wissenschaftliche Untersuchungen sollte – in Abhängigkeit vom Analyseziel – das **Teilen der zur Erhebung genutzten Wearables explizit ausschließen**.
- Sofern sinnvoll, können Teilnehmende befragt werden, ob und wenn ja in welchem Ausmaß Geräte geteilt oder fremdverwendet wurden. **Von mehreren Personen verwendete Geräte können ausgeschlossen** oder – je nach Analyseziel – besonders berücksichtigt werden.
- Mit Hilfe von Algorithmen des maschinellen Lernens kann es möglich sein, **unterschiedliches Nutzungsverhalten** zu identifizieren und die erhobenen Daten damit unterschiedlichen Nutzenden zuzuordnen (Ochoa/Bort/Porcar 2018). Dabei sind datenschutzrechtliche Vorgaben zu beachten (vgl. Kapitel 4).

4 Forschungsethik und Datenschutz

■ Bei Datenerhebung mit neuer Informationstechnologie stellen sich spezifische forschungsethische und datenschutzrechtliche Probleme. Ihre Berücksichtigung sichert letztlich die Datenqualität und die einwandfreie Möglichkeit der Daten(nach)nutzung ab. Hieraus ergeben sich insbesondere spezifische Anforderungen an die Gestaltung einer informierten Einwilligung.

4.1 Forschungsethische und datenschutzrechtliche Probleme

Datenerfassung mit neuer Informationstechnologie findet häufig im Alltag von Personen statt. Die Datenerhebung kann sich auch auf Situationen beziehen, welche die Privatsphäre betreffen, wobei unter Privatsphäre der „Ort unbeeinflusst und unbeobachtet selbstgestalteten Lebens" (Deutscher Ethikrat 2018: 190) verstanden werden kann. Insbesondere kann die Datenerhebung in Situationen stattfinden, welche die Intimität tangieren, worunter der Deutsche Ethikrat (ebd.: 29) Lebensbereiche versteht, „die ausschließlich den unmittelbar Betroffenen vorbehalten bleiben und deren Details diese – wenn überhaupt – nur ausgewählten anderen selbstbestimmt zugänglich machen". Die Sicherstellung von Privatheit und die freie Entscheidung darüber, in welchen Lebensbereichen welche Daten erhoben bzw. gespeichert werden dürfen, ist von zentraler forschungsethischer Bedeutung (Langheinrich und Schaub 2019). Hinzu kommt, dass Teilnehmenden von Studien möglicherweise nicht in vollem Umfang bewusst ist, inwieweit ihre Privatsphäre durch Datenerhebung mit neuer Informationstechnologie bedroht ist. Dies stellt Herausforderungen an die Aufklärung von Studienteilnehmenden, die Sicherstellung der Souveränität über die eigenen Daten und die Gestaltung von informierten Einwilligungen dar (Deutscher Ethikrat 2018; Kelly et al. 2013; Langheinrich und Schaub 2019).

Die Vielzahl der Daten, die anhand neuer Informationstechnologie erhoben werden, sowie deren Verknüpfungsmöglichkeiten machen es zunehmend schwierig, die Anonymität von Studienteilnehmenden sicherzustellen (Langheinrich und Schaub 2019; Miller 2012). Dies gilt insbesondere, wenn genaue Ortsdaten mittels GPS (Apte et al. 2019) oder Audio- und Videodaten (Kelly et al. 2013) erhoben werden. Werden Daten im Projekt aufbereitet und weiterverarbeitet, kann es auftreten, dass die bearbeitenden Personen die Studienteilnehmenden z. B. an ihrer Stimme erkennen (Robbins 2017). Sobald Informationen einer Person zugeordnet werden können gelten die Daten nicht mehr als anonym. Das Reidentifizierungsrisiko ist bei der Verwendung neuer Technologie erheblich und muss durch geeignete Maßnahmen minimiert werden. Darüber hinaus ist nicht absehbar, in welcher Weise zukünftige datenanalytische Methoden eine Reidentifizierung erlauben, die derzeit noch nicht möglich wäre. Ist die Anonymität nicht sichergestellt, unterliegt die Datenerhebung und -verarbeitung der Datenschutzgrundverordnung (DSGVO). Angesichts des sehr hohen Reidentifizierungsrisikos wird im Zweifel bei der Verwendung neuer Technologie empfohlen, die Datenschutzgrundverordnung anzuwenden, auch wenn Daten nach heutigem Standard anonym erscheinen. Besteht ein hohes Risiko für die Rechte und Freiheiten der untersuchten Personen, ist nach Artikel 35 der DSGVO in jedem Fall eine Datenschutz-Folgenabschätzung notwendig. Laut DSGVO besteht dieses Risiko insbesondere, wenn sensible Daten, wie beispielsweise Gesundheitsdaten, in großem Umfang verarbeitet werden und sofern „neue Technologien" umfangreich zum Einsatz kommen (DSGVO Art. 35 Abs. 3, Erwägungsgrund 91, siehe Kasten). Sofern personenbezogene Daten erhoben werden, ist nach der DSGVO und wie in Kapitel 4.2 spezifiziert, außerdem eine informierte Einwilligung einzuholen.

§

Auszug aus der Datenschutzgrundverordnung (DSGVO)

Artikel 35 Datenschutz-Folgenabschätzung

1) Hat eine Form der Verarbeitung, insbesondere bei Verwendung neuer Technologien, aufgrund der Art, des Umfangs, der Umstände und der Zwecke der Verarbeitung voraussichtlich ein hohes Risiko für die Rechte und Freiheiten natürlicher Personen zur Folge, so führt der Verantwortliche vorab eine Abschätzung der Folgen der vorgesehenen Verarbeitungsvorgänge für den Schutz personenbezogener Daten durch. Für die Untersuchung mehrerer ähnlicher Verarbeitungsvorgänge mit ähnlich hohen Risiken kann eine einzige Abschätzung vorgenommen werden.

2) Der Verantwortliche holt bei der Durchführung einer Datenschutz-Folgenabschätzung den Rat des Datenschutzbeauftragten, sofern ein solcher benannt wurde, ein.

3) Eine Datenschutz-Folgenabschätzung gemäß Absatz 1 ist insbesondere in folgenden Fällen erforderlich:
   - systematische und umfassende Bewertung persönlicher Aspekte natürlicher Personen, die sich auf automatisierte Verarbeitung einschließlich Profiling gründet und die ihrerseits als Grundlage für Entscheidungen dient, die Rechtswirkung gegenüber natürlichen Personen entfalten oder diese in ähnlich erheblicher Weise beeinträchtigen;
   - umfangreiche Verarbeitung besonderer Kategorien von personenbezogenen Daten gemäß Artikel 9 Absatz 1[2] oder von personenbezogenen Daten über strafrechtliche Verurteilungen und Straftaten gemäß Artikel 10 oder
   - systematische umfangreiche Überwachung öffentlich zugänglicher Bereiche;

(…)

7) Die Folgenabschätzung enthält zumindest Folgendes:
   - eine systematische Beschreibung der geplanten Verarbeitungsvorgänge und der Zwecke der Verarbeitung, gegebenenfalls einschließlich der von dem Verantwortlichen verfolgten berechtigten Interessen;
   - eine Bewertung der Notwendigkeit und Verhältnismäßigkeit der Verarbeitungsvorgänge in Bezug auf den Zweck;
   - eine Bewertung der Risiken für die Rechte und Freiheiten der betroffenen Personen gemäß Absatz 1 und die zur Bewältigung der Risiken geplanten Abhilfemaßnahmen, einschließlich Garantien, Sicherheitsvorkehrungen und Verfahren, durch die der Schutz personenbezogener Daten sichergestellt und der Nachweis dafür erbracht wird, dass diese Verordnung eingehalten wird, wobei den Rechten und berechtigten Interessen der betroffenen Personen und sonstiger Betroffener Rechnung getragen wird.

Herausforderungen ergeben sich daraus, dass die Datenerhebung im sozialen Umfeld stattfinden kann. Die Datenerfassung kann sich hierbei auch explizit auf die Erfassung des sozialen Umfeldes beziehen, muss dies aber nicht zwangsläufig tun. In jedem Fall können Daten anderer Personen anfallen. So können bspw. durch Video- und Audioaufnahmen Daten von Personen erfasst werden, die nicht explizit ihre Studienteilnahme erklärt haben (Brown/Blake/Sherman 2017; Kelly et al. 2013; Robbins 2017). Es müssen daher Vorkehrungen getroffen werden, damit Personen bewusst ist, dass sie an Datenerhebungen teilnehmen, dass die Freiwilligkeit ihrer Teilnahme an der Datenerhebung gesichert ist und dass sie die Möglichkeit haben, die Erhebung ihrer Daten zu verweigern oder ihre Einwilligung zu widerrufen (Art. 7 Absatz 3 DSGVO, insb. ist dies relevant für besondere Kategorien personenbezogener Daten nach Art. 9 DSGVO). Erschwerend kommt hinzu, dass die Zustimmung zur Datenerhebung nicht nur von den „erfassten" Teilnehmenden selbst, sondern auch von den Personen,

2 Unter der Verarbeitung besonderer Kategorien personenbezogener Daten versteht die DSGVO (Art. 9 Absatz 1) die Verarbeitung von Daten, „aus denen die rassische und ethnische Herkunft, politische Meinungen, religiöse oder weltanschauliche Überzeugungen oder die Gewerkschaftszugehörigkeit hervorgehen, sowie die Verarbeitung von genetischen Daten, biometrischen Daten zur eindeutigen Identifizierung einer natürlichen Person, Gesundheitsdaten oder Daten zum Sexualleben oder der sexuellen Orientierung einer natürlichen Person".

mit denen sie interagieren (sog. Drittpersonen), eingeholt werden muss. Dies ist häufig aufwändig oder in manchen Untersuchungskontexten ausgeschlossen. Soweit es möglich ist, Informationen von Drittpersonen völlig anonymisiert zu erheben, findet die Datenschutzgrundverordnung (DSGVO) keine Anwendung. Allerdings kann es trotzdem aus forschungsethischer Sicht problematisch sein, Drittpersonen ohne ihr Wissen zu untersuchen. Zumindest – wie bereits erwähnt – ist eine vollständige Anonymität aufgrund der informationsreichen Datenmassen häufig nicht möglich.

Möglicherweise wird illegales bzw. strafrechtlich relevantes Verhalten erhoben. In einer solchen Situation ergeben sich die Fragen, ob (1) dieses den zuständigen Behörden gemeldet werden muss, (2) ob die Daten auf Anfrage herausgegeben werden müssen und ob (3) die Teilnehmenden vorab über solche Fälle informiert werden müssen. Grundsätzlich gilt dabei, dass die Wissenschaftlerin oder der Wissenschaftler nicht verpflichtet ist, im Rahmen einer Studie erhaltenes Wissen über illegales bzw. strafrechtlich relevantes Verhalten den zuständigen Behörden mitzuteilen, es sei denn es handelt sich um besonders schwerwiegende Straftaten (§ 138 Strafgesetzbuch [StGB]). Diese betreffen Mord (§ 211 StGB), Totschlag (§ 212 StGB), Verbrechen gegen die persönliche Freiheit (§§ 232 ff. StGB), Hoch- (§§ 81 ff. StGB) oder Landesverrat (§§ 94 ff. StGB), Geld- oder Wertpapierfälschung (§§ 146 ff. StGB), Raub oder Erpressung (§§ 249 ff. StGB) oder eine gemeingefährliche Straftat (§§ 306 ff. StGB). Bei diesen besonders schweren Straftaten ist auch die Kenntnis von geplanten Straftaten den zuständigen Strafverfolgungsbehörden (Polizei, Staatsanwaltschaft) anzuzeigen, da sich Forschende sonst selbst strafbar machen (§ 138 StGB). Bei allen Straftaten – d. h., auch bei nicht schwerwiegenden Straftaten – gilt, dass ggf. die Studienunterlagen bei Ermittlungen der Strafverfolgungsbehörden diesen herausgegeben werden müssen. Da Forschende bisher nicht in die Kategorie der Berufsgeheimnisträger (i.S.d. § 203 StGB) fallen, können die Unterlagen von den Strafverfolgungsbehörde beschlagnahmt werden (§ 94 Absatz 2 Strafprozessordnung [StPO]). Aus ethischer Sicht sollten die Studienteilnehmer hierüber aufgeklärt werden.

Durch die Speicherung von Daten auf Smartphones bzw. die Datenübertragung mittels Internet besteht die Gefahr, dass sich Dritte unberechtigterweise Zugang zu den Daten verschaffen, z. B. durch Hacking (Carter et al. 2015). Diese Gefahr ist zu bedenken nach Möglichkeit auszuschließen, was dokumentiert werden muss (DSGVO Art. 24 Abs. 1). In Bezug auf Forschungsethik und Datenschutz wurden in der Fachliteratur entsprechende Empfehlungen formuliert, die im Folgenden zusammengefasst und ergänzt werden.

Empfehlungen in Bezug auf Anonymität

1) **Anonymisierungs- und Pseudonymisierungsstrategien** sind grundsätzlich anzuwenden. Danach sind Daten nach dem Erreichen des Forschungszwecks grundsätzlich zu anonymisieren und bis dahin so zu speichern, dass Informationen durch Pseudonymisierung nicht zugeordnet werden können. (§ 27 Absatz 3 Bundesdatenschutzgesetz [BDSG]).
2) Solange eine Anonymisierung nicht sichergestellt bzw. erfolgt ist, müssen die rechtlichen Vorgaben der DSGVO umgesetzt werden. Insbesondere ist die **Notwendigkeit einer Datenschutz-Folgenabschätzung zu prüfen** und ggf. durchzuführen.
3) Daten sollten **nur auf sicherem Wege gespeichert, verarbeitet und transferiert** werden, z. B. unter Rückgriff auf Verschlüsselungstechniken (Brown/Blake/Sherman 2017; Carter et al. 2015).
4) Generell können One-Way Hashfunktionen zur Wahrung der **(formalen) Anonymität von Studienteilnehmenden** eingesetzt werden, so dass ein unmittelbarer Rückschluss auf eine bestimmte Person nicht länger möglich ist (siehe Naor und Yung 1989).
5) Von der Speicherung von Daten, welche die Reidentifizierung von Personen relativ leicht ermöglicht (z. B. Ortsinformationen) ist abzusehen, wenn sie nicht zur Beantwortung der konkreten Fragestellung benötigt werden. So sollten bspw. Geodaten direkt (z. B. per GPS, Wifi oder Mobilfunkdaten) oder indirekt (z. B. über Kontextinformation) nur dann erhoben werden, wenn sie zur Beantwortung der Fragestellung notwendig sind. Es sollten auch in anderen Datenquellen **„Spuren von Lokation" vermieden** werden (Geoinferencing bei Twitter-Daten), **sofern sie zur Beantwortung der Forschungsfrage nicht benötigt** werden (Johnson et al. 2016).

6) Es sollten **datenart-spezifische Möglichkeiten zur Anonymisierung** (die teils mit Informationsverlust einhergehen) **genutzt** werden, wie z. B. die Transformation (Verzerrung) von Stimmen bei Audioaufnahmen oder die Transformation von Koordinatensystemen (unter Beibehaltung der Topologie) bei räumlichen Informationen (Mainali/Shepherd/Petitcolas 2019).

7) **Daten** (wie z. B. Ortsdaten, Audiodaten) können **weniger präzise oder bereits weiterverarbeitet** (z. B. durch Behavioral Signal Processing) **abgespeichert** und die Rohdaten noch auf dem Gerät gelöscht werden, um die Möglichkeit der Reidentifikation zu verringern (z. B. Feng et al. 2018; Wyatt et al. 2011). Hier ergibt sich ein **Spannungsverhältnis mit den qualitätssichernden Empfehlungen** zur Konstruktvalidität (s. Empfehlungen in Kapitel 3.3.2) – es ist sinnvoll, einen Interessenabgleich durchzuführen und zu dokumentieren.

8) Daten mit **identifizierbaren Informationen** (z. B. volle Namen, Adressen, Kontonummern), die bspw. mittels Audio- oder Videoaufnahmen erhoben werden, sollten im Kodierprozess/weiteren Verlauf **gelöscht bzw. herauseditiert** werden (z. B. durch „beepen") (Robbins 2017).

9) **Erkennen datenverarbeitende Personen** (z. B. Kodierende) **die Studienteilnehmenden** (z. B. anhand ihrer Stimme), sollten sie die Weiterverarbeitung der Daten beenden und sie einer anderen Person übertragen (Robbins 2017).

Empfehlungen in Bezug auf den sozialen Kontext/beteiligte Dritte

1) **Personen**, die sich im regelmäßigen Kontakt mit den an einer Untersuchung teilnehmenden Personen befinden (z. B. Familie, befreundete Personen, Arbeitskolleginnen und -kollegen) und **von denen Daten erhoben werden, sind über die Datenerhebung** zu informieren und ihre Zustimmung ist einzuholen (Kelly et al. 2013).

2) Das **Aufzeichnungsrisiko sollte sichtbar gemacht werden**, um die **Privatheitserwartung bei Drittpersonen zu minimieren**. Hierzu können die an einer Untersuchung Teilnehmenden einen Recording-Anstecker tragen, der auf das Aufzeichnungsrisiko hinweist („Dieses Gespräch kann aufgezeichnet werden"), da dann von einer (passiven) Zustimmung der Probanden ausgegangen werden kann und die Aufzeichnung dann ethisch vertretbar ist (Mehl 2017; Robbins 2017). Alternativ sollten die an einer Untersuchung Teilnehmenden instruiert werden, das Aufzeichnungsrisiko Gesprächspartnern zu signalisieren (Robbins 2017).

3) **Geräte sollten ausgeschaltet werden, wenn** dies von Personen im sozialen Umfeld **gewünscht** wird (Brown/Blake/Sherman 2017; Robbins 2017).

4) Soweit **keine explizite Einwilligung** vorliegt, die personenbezogenen Daten nutzen zu dürfen, sollten **bei Audioaufnahmen die Stimmen dritter Personen** durch entsprechende Filter **verzerrt** werden.

5) Soweit **keine explizite Einwilligung** vorliegt, die personenbezogenen Daten nutzen zu dürfen, sollten **bei Videoaufnahmen die Gesichter von Personen verpixelt** werden.

6) Für die **Veröffentlichung von Daten**, die eine Identifikation Dritter erlauben, ist es notwendig, deren **Zustimmung einzuholen** (Kelly et al. 2013).

7) Personen des sozialen Umfelds, die anhand von Aufzeichnungen identifizierbar sind, muss die Möglichkeit eingeräumt werden, die **Zustimmung zur Datennutzung für bestimmte Zwecke jederzeit zu ändern und zu widerrufen** (Kelly et al. 2013).

Empfehlungen in Bezug auf Privatheit

1) Untersuchungsteilnehmende sollten präzise darüber informiert werden, in welcher Weise ihre Daten erhoben, gespeichert und weiterverarbeitet werden und welche Risiken in Bezug auf ihre Privatheit entstehen. Insbesondere sollten sie im Detail darüber aufgeklärt werden, **wie** sie **die Korrektur und Löschung von Daten fordern und Änderungen ihrer Zustimmungserklärungen vornehmen lassen** können (Kelly et al. 2013; Langheinrich und Schaub 2019) (s. Kapitel 4.2 – informierte Einwilligung).

2) Untersuchungsteilnehmenden sollte die **volle Kontrolle über ihre Daten** gegeben werden (informationelle Selbstbestimmung). So ist Personen die Möglichkeit einzuräumen, ihre eigenen Daten in zugänglichem Format zu erhalten (Art. 20 DSGVO), u. a. auch, um die Löschung spezifischer Sequenzen (**retroaktive Zensur**) fordern zu können (Kelly et al. 2013; Langheinrich und Schaub 2019; Mehl 2017).

3) Sofern möglich, sollten Untersuchungsteilnehmende **private Daten** (z. B. Audio- und Bildaufnahmen) **löschen können**, bevor die Forschungsdaten an die Forschenden weitervermittelt werden (Brown/Blake/Sherman 2017; Robbins 2017).

4) Das Aufnahmegerät sollte die **Möglichkeit einer proaktiven Zensur**, z. B. in Form eines Privacy-Buttons bieten, um die Datenaufnahme zu unterbrechen (Kelly et al. 2013; Langheinrich und Schaub 2019; Robbins 2017).

5) **Aufnahmegeräte sollten entfernt werden können**, wenn sich Untersuchungsteilnehmende dadurch in spezifischen Situationen wohler fühlen (Kelly et al. 2013).

6) Zum Schutz bei der Aufzeichnung von illegalem oder rufschädigendem Verhalten sollen **für die Teilnehmenden pro- und retroaktive Zensierungsmöglichkeiten gegeben sein**. Untersuchungsteilnehmende sollten darauf hingewiesen werden, dass (1) besonders schwerwiegende Straftaten den zuständigen Behörden gemeldet werden müssen und (2) bei allen Straftaten Studienunterlagen bei Ermittlungen der Strafverfolgungsbehörden diesen herausgegeben werden müssen.

7) **Kontinuierliche Aufzeichnungen** (z. B. bei Audioaufnahmen) **sollten vermieden werden**, sofern sie für die Beantwortung einer Forschungsfrage nicht notwendig sind. Kurze Segmente (30 Sekunden oder weniger) mit entsprechenden Zwischenpausen sind kontinuierlichen Aufzeichnungen vorzuziehen (sofern die Forschungsfrage dies zulässt) (Mehl 2017).

8) **Audio- und Bilddaten**, die es ermöglichen, Personen zu identifizieren, **sollten nicht weitergegeben werden, sofern keine explizite Zustimmung** der Personen, deren Daten erfasst wurden, vorliegen (z. B. in einer expliziten Zustimmungserklärung über die zukünftige Datennutzung) (Kelly et al. 2013).

9) **Rohdaten von Sensoren**, bei denen die Gefahr besteht, dass sie bei späteren Analysen neue personenbezogene Einblicke ermöglichen (z. B. Videodaten) sollten **nur in einer bearbeiteten Form** (z. B. mit einer geringeren Auflösung der Bilder oder mit weniger Frames pro Sekunde), **weitergegeben oder veröffentlicht** werden (z. B. Muaaz und Mayrhofer 2017; Ranjan und Whitehouse 2015).

10) **Sprachaufnahmen sollten dem Prinzip der Datenminimierung folgen**. Es sollen nur so viele Sprachaufnahmen vorgenommen werden, wie zur Verhaltensbestimmung benötigt werden (z. B. kurze Segmente [30 Sekunden oder weniger], keine hochfrequente Datenerhebung (Mehl 2017)).

11) Werden **Daten mit Smartphones erhoben**, so ist sicherzustellen, dass ein Zugriff auf private Daten des Smartphone-Besitzenden nicht möglich ist und nur die Daten weitervermittelt werden, deren Verarbeitung die Person zugestimmt hat.

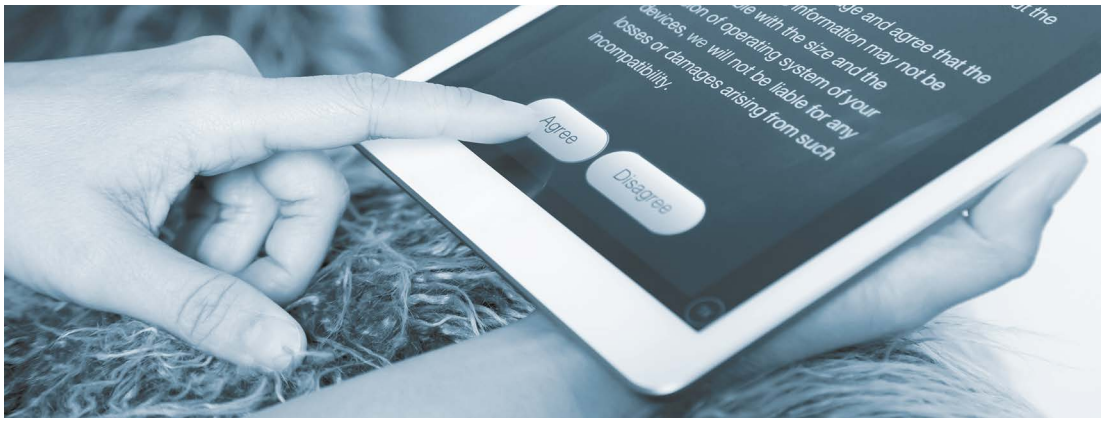

4.2. Informierte Einwilligung

Nicht nur aus forschungsethischen, sondern auch aus datenschutzrechtlichen Gründen ist es geboten, von Teilnehmenden an Untersuchungen eine informierte Einwilligung einzuholen. Eine informierte Einwilligung – und damit die freie Entscheidung zur Untersuchungsteilnahme – setzt voraus, dass sie die Personen über Nutzen und Risiken der Datenerhebung und -verarbeitung (s. Abschnitt 4.1) in verständlicher Weise aufklärt (Carter et al. 2015). Aufgrund der Komplexität der Datenerhebung und -verarbeitung mit neuer Informationstechnologie muss hierbei eine Balance gefunden werden. Einerseits muss sichergestellt werden, dass Personen verstanden haben, welche Implikationen eine Untersuchung für sie hat, andererseits dürfen sie durch eine zu detailreiche Aufklärung nicht überfordert werden (Carter et al. 2015; Langheinrich und Schaub 2019). Eine zu detaillierte und lange Einwilligungserklärung kann dazu führen, dass sie nicht oder nicht vollständig gelesen wird (Langheinrich und Schaub 2019).

4.2.1 Einwilligungskonzepte

Der Deutsche Ethikrat (2018) hat sich mit der Frage der Gestaltung von informierten Einwilligungen in Bezug auf Big Data auseinandergesetzt.[3] Hintergrund ist der Sachverhalt, dass bei Datenerhebungen im Bereich von Big Data die Fragestellungen häufig im Verlauf der Datensammlung und -analyse neu entstehen, Datenverknüpfungen notwendig machen und sich hierdurch neue Risiken bilden können. Klassische Aufklärungs- und Einwilligungskonzepte, die im Rahmen eng umschriebener klinischer sowie sozial- und verhaltenswissenschaftlicher Studien Anwendung finden, haben in Bezug auf Big-Data-Fragestellungen ihre Grenzen. Die Möglichkeiten, die Datenerhebung mit neuer Informationstechnologie eröffnet, weisen aufgrund der Datenmenge und der Verknüpfungsmöglichkeiten mit anderen Datenquellen Bezüge zu Big-Data-Fragestellungen auf. Einwilligungskonzepte, die im Rahmen von Big Data diskutiert werden, können daher auch für Datenerhebung mit neuer Informationstechnologie von Nutzen sein. Der Deutsche Ethikrat (2018: 183-185) unterscheidet drei Einwilligungsmodelle: die Blanko-Einwilligung, die dynamische Einwilligung und die Kaskaden- oder Meta-Einwilligung. Die DSGVO eröffnet darüber hinaus die Möglichkeit einer breiten Einwilligung.

3 Der Deutsche Ethikrat (2018: 54) definiert Big Data wie folgt: „Big Data ist der Umgang mit großen Datenmengen, der darauf abzielt, Muster zu erkennen und daraus neue Einsichten zu gewinnen, und der hierzu angesichts der Fülle und Vielfalt der Daten sowie der Geschwindigkeit, mit der sie erfasst, analysiert und neu verknüpft werden, innovative, kontinuierlich weiterentwickelte informationstechnologische Ansätze nutzt."

Einwilligungsmodelle (Deutscher Ethikrat 2018: 183–185; DSGVO)

Blanko-Einwilligung

Untersuchungsteilnehmende stimmen einer inhaltlich unbestimmten zukünftigen Nutzung und der Weitergabe der Daten zu. Alle weiteren Entscheidungen darüber, was mit den Daten passiert, werden nicht mehr von den Untersuchungsteilnehmenden, sondern von der Verwaltung der Datenbanken getroffen.

Dynamische Einwilligung

Untersuchungsteilnehmende werden wiederholt kontaktiert, um ihre informierte Einwilligung zu einzelnen Fragestellungen einzuholen. Sie stehen in regelmäßigem Kontakt mit einer Datenbank (z. B. über Online-Plattform oder telefonische Kontakte).

Kaskaden- oder Meta-Einwilligung

Hierbei handelt es sich um eine Erweiterung der dynamischen Einwilligung. Die Einwilligung muss nicht zwangsläufig für jede Fragestellung neu eingeholt werden, sondern die Untersuchungsteilnehmenden können zwischen verschiedenen Optionen wählen. Neben dem klassischen dynamischen Einwilligungsmodell können sie bspw. ihre Zustimmung zu verschiedenen Kategorien von Forschungsfragen geben, ohne bei jeder einzelnen Forschungsfrage kontaktiert zu werden. Es ist auch möglich, die Entscheidung an andere Personen oder Einrichtungen (z. B. Expertengremien) treuhänderisch zu delegieren oder aber die eigenen Daten für jegliche Nutzung uneingeschränkt zur Verfügung zu stellen bzw. eine Teilnahme grundsätzlich abzulehnen. Die einzelnen Optionen können miteinander verknüpft werden bzw. zwischen den Optionen kann über die Zeit hinweg gewechselt werden.

Breite Einwilligung nach der DSGVO

Speziell für die wissenschaftliche Forschung wurde in Erwägungsgrund 33 der DSGVO die Möglichkeit einer "breiten" Einwilligung geschaffen (der sogenannte broad consent). Der europäische Verordnungsgeber geht dabei davon aus, dass es häufiger vorkommen kann, dass der Zweck der Verarbeitung personenbezogener Daten für Zwecke der wissenschaftlichen Forschung zum Zeitpunkt der Erhebung der personenbezogenen Daten nicht vollständig angegeben werden kann. Daher lässt er die Möglichkeit zu, dass Untersuchungsteilnehmende a) für bestimmte Bereiche wissenschaftlicher Forschung oder für Teile von Forschungsprojekten, b) in dem vom verfolgten Zweck zugelassenen Maß und c) unter Einhaltung anerkannter ethischer Standards der wissenschaftlichen Forschung eine "breite" Einwilligung erklären. Der "bestimmte Bereich" muss dabei einen Zusammenhang mit dem ursprünglichen Forschungsziel haben.

Aufgrund der Anpassung der Optionen an die Bedarfe der Untersuchungsteilnehmenden ermöglicht das Kaskadenmodell, das Selbstbestimmungsrecht in Bezug auf die eigenen Daten passgenau sicherzustellen.

Beispiel: Rekrutierungs- und Einwilligungsprozess der IAB-SMART-Studie

Als Beispiel für die Umsetzung der Anforderungen der EU-DSGVO im Rahmen einer Datenerhebung mit neuer Technologie wird im Folgenden der Rekrutierungs- und Einwilligungsprozess der IAB-SMART-Studie (Kreuter et al. 2018) vorgestellt. Im Rahmen dieser Studie wurden Teilnehmende einer Panelbefragung des Instituts für Arbeitsmarkt- und Berufsforschung (IAB) eingeladen, eine Forschungs-App, die IAB-SMART-App, auf ihren Smartphones zu installieren. Mithilfe dieser App wurden zwei Arten von Daten erhoben: Einerseits durch kurze Befragungen (etwa alle 14 Tage) und andererseits durch die Bitte, den Forschenden Zugriff auf passive Daten zu erteilen. Letztere waren auf fünf Berechtigungen verteilt: (1) Netzwerkqualität und Standortinformationen, (2) Interaktionsverlauf, (3) Merkmale des sozialen Netzwerks, (4) Aktivitätsdaten, (5) Smartphonenutzung. Die folgenden Informationen sind überwiegend Kreuter et al. (2018) entnommen. Sämtliche Unterlagen der Studie sind unter https://www.iab.de/smart abrufbar.

Die Rekrutierung wurde postalisch vorgenommen. Das Schreiben an die potenziell Teilnehmenden enthielt ein kurzes Einladungsschreiben mit Link zum Download-Bereich der App und eindeutigem Registrierungscode, Informationen zum Datenschutz, eine genaue Beschreibung der Datenerhebungsfunktionen, eine Erläuterung zu Incentives und eine Broschüre, in der schrittweise der Installationsprozess erläutert wurde. Die Beschreibung der Datenerhebungsfunktionen wurde in ein eigenes Dokument ausgelagert, um sie hervorzuheben. Dort wurde für jede später abgefragte Datenerhebungsfunktion in möglichst einfacher Sprache erläutert, welche Daten erhoben werden und zu welchem Forschungszweck sie benötigt werden.

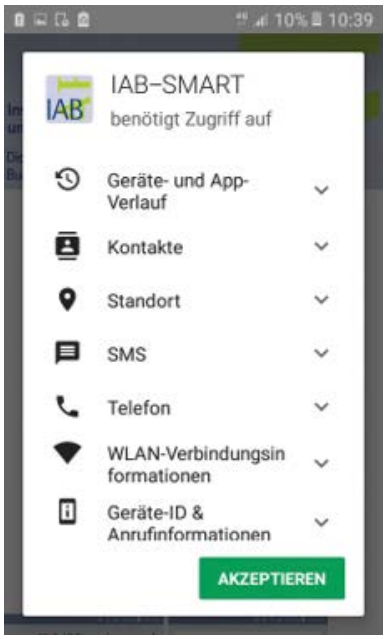

Screenshot 1: aus dem Download-Bereich des Play Stores: Akzeptieren der Berechtigungen

Der weitere Aufnahmeprozess in die Studie wurde anhand der Bestimmungen der Art. 5 und 7 und der Erwägungsgründe 32 und 33 der DSGVO gestaltet. Das betrifft insbesondere die Dokumentation, wer wann worin eingewilligt hat (Art. 7 Absatz 1), die Abgrenzung der Einwilligung von anderen Sachverhalten (Hervorhebungsgebot in Art. 7 Absatz 2), die Widerrufbarkeit der Einwilligung (Art. 7 Absatz 3), Transparenz durch klare und einfache Sprache (Art. 7 Absatz 2), die aktive Einwilligung im Sinne eines Opt-in (Erwägungsgrund 32) und die Zweckbindung (Erwägungsgrund 33 und Art. 5 Absatz 1b).

Bei der Umsetzung ist jedoch zu beachten, dass in einem ersten Schritt die Besonderheiten der App-Installation auf Android Smartphones zum damaligen Zeitpunkt zu berücksichtigen waren. Der Installationsprozess konnte nur abgeschlossen werden, wenn die nutzende Person bereits in einem ersten Schritt alle Berechtigungen akzeptiert, welche die App potenziell benötigen könnte (siehe Screenshot 1). Die Zustimmung an dieser Stelle war lediglich notwendige technische Voraussetzung für die Installation und führte noch zu keiner Datenerfassung. Erfreulicherweise haben die aktuellen Androidversionen ein verbessertes Berechtigungsmanagement, welches erst direkt bei der eigentlichen Nutzung nach der jeweiligen Berechtigung fragt. So werden überflüssige Berechtigungen vermieden und Probanden haben weiterhin die individuelle Kontrolle.

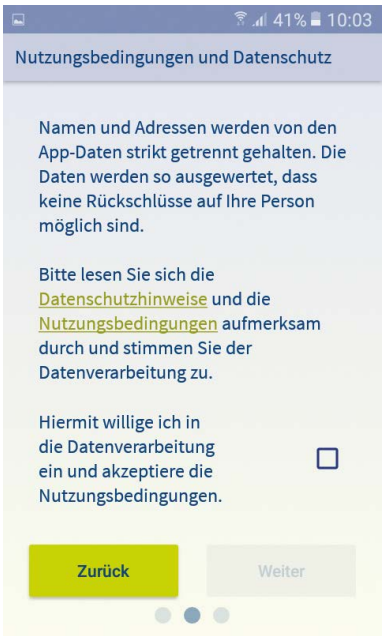

Screenshot 2: Einwilligung in Datenverarbeitung und Nutzungsbedingugen

Beim ersten Öffnen der App wurde durch die Abfrage des Registrierungscodes sichergestellt, dass nur eingeladene Personen an der Studie teilnehmen konnten. Danach – hier handelt es sich wieder um eine spezifische Anforderung von Android – wurden die Teilnehmenden gebeten, den allgemeinen Nutzungsbedingungen und Datenschutzhinweisen zuzustimmen (siehe Screenshot 2). Diese waren auf dem Bildschirm verlinkt und den Eingeladenen vorab mit den genannten Unterlagen des Einladungsschreibens auch postalisch zugesandt worden. Eine Teilnahme und die damit verbundene Datenerhebung war nur möglich, wenn an dieser Stelle die Zustimmung erteilt wurde.

Es ist wichtig festzuhalten, dass die App auch mit dieser Einwilligung noch keine passiven Daten vom Smartphone der Teilnehmenden erheben konnte. Die Steuerung der einzelnen Datenerhebungsberechtigungen erfolgte über die Aktivierungen von Funktionen auf dem folgenden Bildschirm (siehe Screenshot 3).

Es wurde die Einwilligung für jeden Forschungszweck einzeln erhoben. Dies erfolgte durch eine aktive Zustimmung (Opt-in): Die Voreinstellung für alle Felder sah keine Einwilligungen vor. Erst durch das aktive Setzen eines Hakens durch die Teilnehmenden wurde die Erhebung aktiviert. Die einzelnen Einwilligungen sind kompakt auf einem Bildschirm dargestellt. Durch Klicken auf die Funktion konnten Erläuterungen angefordert und gelesen werden. Die so aufrufbaren Erläuterungen waren die Kurzform einer ausführlichen Beschreibung im Einladungsschreiben. Durch Aktivierung einer Funktion an dieser Stelle wurde der Zugriff auf die entsprechenden Daten möglich.

Um der Bestimmung zu entsprechen, dass der Widerruf genauso einfach möglich sei wie die Zustimmung selbst (siehe DSGVO Art. 7 Absatz 3), gab es die Möglichkeit, über den Menüpunkt „Einstellungen“ im Hauptmenü der App erneut auf diesen Bildschirm zu gelangen und diese Berechtigungen jederzeit durch Antippen des gesetzten Hakens wieder zu entziehen (siehe Screenshot 4).

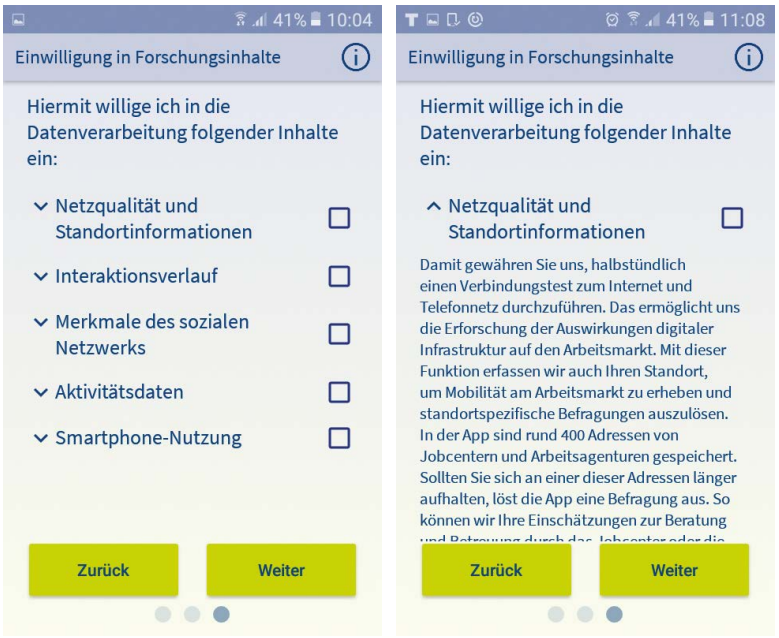

Screenshot 3: Einwilligung in passive Datenerhebung

Screenshot 4:
Hauptmenü und Änderung der Einwilligung in Forschungsinhalte

4.2.2 Zustimmung dritter Personen

Neben Daten der Teilnehmenden können auch Daten von Dritten (Personen des sozialen Kontextes) erhoben worden sein. Hier ist es teilweise nicht möglich oder nicht sinnvoll, eine schriftliche Einwilligung einzuholen. Es muss in jedem Fall sichergestellt sein, dass diese Personen realistisch und ohne Aufwand ihrerseits über das Aufzeichnungsrisiko informiert sind (z. B. durch einen sichtbaren Recording-Anstecker, der von der teilnehmenden Person getragen wird). Es wird davon ausgegangen, dass die dritten Personen sich im vollen Bewusstsein des Aufzeichnungsrisikos entschieden haben, sich in Gegenwart des Mikrofons oder der Kamera „zu verhalten". Einverständnis ist in diesem Zusammenhang definiert als eindeutige bestätigende Handlung, also z. B. die Fortführung eines Gesprächs. Es bedarf hier zwar nicht zwangsläufig einer schriftlichen Einwilligung, aber die Datenschutzgrundverordnung verlangt den Nachweis einer Einwilligung aller Gesprächspartner. Dieser Nachweis kann auch elektronisch erfolgen. Da die Datenschutzgrundverordnung keinen Formzwang bei der Einwilligung kennt[4], kann sie ggf. auch durch Aufzeichnen einer mündlichen Erklärung nachgewiesen werden. Auch eine konkludente Handlung – etwa, weil auf das Aufzeichnungsrisiko transparent hingewiesen wurde und die dritte Person in dessen Kenntnis in das Gespräch eintritt – kann als Einwilligung gelten. Die Wissenschaftlerin oder der Wissenschaftler muss die Abgabe der Einwilligung dokumentieren.

Empfehlungen in Bezug auf die informierte Einwilligung

1) **Teilnehmende** müssen über den Nutzen, die Risiken und die Form der Datenerhebung sowie über die Zwecke der Datennutzung, die Datenspeicherung und -weiterverwendung **in verständlicher Form aufgeklärt** werden, so dass sie informiert und aufgrund freier Entscheidung in die Verarbeitung ihrer Daten einwilligen können.
2) Die **Zustimmung** zur Datennutzung für bestimmte Zwecke **sollte jederzeit geändert und widerrufen werden können**.
3) Um sicherzustellen, dass **Einwilligungserklärungen** vollständig gelesen werden, sind **Kurzformen mit weiteren Erklärungen im Anhang denkbar**. In Internetstudien kann mit Videos gearbeitet werden, die Sinn, Vorgehen und Datenschutz der Studie erklären, wobei die Felder zur Bestätigung der Einwilligung erst erscheinen, wenn die Videos vollständig abgespielt wurden und geprüft wurde, ob der Ton angestellt war.
4) Um die Datennutzung langfristig sicherzustellen und das Selbstbestimmungsrecht der Teilnehmenden angemessen zu berücksichtigen, könnte ein **kaskadisches Einwilligungsmodell** einen Lösungsansatz darstellen.
5) Die **Freiwilligkeit der Teilnahme** muss stets gewährleistet bleiben. Der Abbruch der Studienteilnahme durch Probanden muss zu jeder Zeit möglich sein.
6) Den Probanden sollte die Möglichkeit zugesichert werden, **Einblick in die erhobenen Daten** zu nehmen und diese korrigieren zu dürfen.
7) Bei Video- und Tonaufnahmen ist die **Zustimmung Dritter** (z. B. Gesprächspartner) erforderlich und muss entsprechend eingeholt werden. Dies kann auch durch konkludente Handlungen erfolgen. Die **Einholung der Einwilligung muss allerdings dokumentiert werden**. Die Form der Dokumentation ist offen. Es können schriftliche Erklärungen, elektronische Erklärungen (E-Mail, Haken setzen in einem elektronischen Formular) oder auch Protokollierungen sein, die belegen, dass Dritte willentlich und informiert an der Studie teilgenommen haben.
8) **Apps sollten nur die für sie funktional notwendigen Berechtigungen** (Zugriff auf Adressbücher, Kamera, Mikrofon, Standortdaten etc.) **einfordern**. Es sollte keine Blanko-Freigabe erfolgen.

4 Nach Art. 5 Absatz 1a) DSGVO muss die Datenverarbeitung auf rechtmäßige Weise erfolgen. Rechtmäßig ist diese - wenn keine gesetzliche Grundlage vorliegt - u. a. wenn nach Art. 6 Absatz 1a DSGVO eine (informierte) Einwilligung vorliegt. Die Einhaltung der Rechtmäßigkeit muss nach Art. 5 Absatz 2 DSGVO nachgewiesen werden ("Rechenschaftspflicht"). Der Nachweis muss dabei nicht schriftlich erfolgen.

5 Datenmanagement

Herausforderungen an das Datenmanagement ergeben sich einerseits aufgrund der hohen Datenmenge, die bei Studien mit neuer Informationstechnologie anfallen kann, andererseits aus den bisher behandelten Herausforderungen in Bezug auf die Güte der Daten sowie forschungsethische und datenschutzrechtliche Aspekte, die in den Abschnitten 3 und 4 besprochen wurden.

5.1 Interoperabilität

In Studien mit neuer Informationstechnologie können umfangreiche Datensätze entstehen. Dies hat Miller (2012: 230) eindrucksvoll illustriert. So verweist er darauf, dass in einer Smartphone-Studie von Kiukkonen et al. (2010), in der 168 Personen über durchschnittlich vier Monate untersucht wurden, folgende Daten angefallen sind: 15 Millionen Bluetooth-Scans, 13 Millionen WLAN-Scans, 15 Millionen GPS-Aufzeichnungen, 4 Millionen App-Nutzungs-Aufzeichnungen, 500.000 Akzelerometer-Messungen, 220.000 Sprachaufnahmen, 130.000 Sprachanrufe, 90.000 Textnachrichten, 28.000 Fotoaufnahmen und 2.000 Videoaufnahmen. Eine solche Datenmenge stellt Herausforderungen an die Datenspeicherung und das Datenmanagement, die eine interdisziplinäre Zusammenarbeit zwischen Sozial-, Verhaltens- und Wirtschaftswissenschaften einerseits und Informatik sowie Datenwissenschaft andererseits erfordern. Moderne IT-Technologie erlaubt es, solche Datensicherungssysteme für große Datensätze zu entwickeln und Probleme, die mit großen Datensätzen verknüpft sind, in den Griff zu bekommen (z. B. Doukas und Maglogiannis 2011; Ranjan et al. 2019).

Bei Datenerhebung mit Wearables oder Smartphones stellt sich das Problem, dass es je nach Studiendesign zum Einsatz unterschiedlicher Geräte kommen kann. Wie kann damit umgegangen werden, dass Daten in verschiedenen Dateiformaten abgelegt wurden? Auch zu Fragen der Interoperabilität werden für den Bereich der Wearables Lösungen entwickelt (z. B. Mezghani et al. 2015), auf die bei der Datenspeicherung zurückgegriffen werden kann.

5.2 Archivierung und Sicherung der Daten

Im Zuge der Replikationskrise verschiedener empirischer Wissenschaften etabliert sich derzeit Open Science als ein neues Wissenschaftsverständnis, das fordert – soweit möglich – Forschungsdaten und eingesetzte Datenverarbeitungsmethoden (z. B. Algorithmen) öffentlich zugänglich zu machen (z. B. Klenk et al. 2019). Die Deutsche Forschungsgemeinschaft hat diese Grundsätze in ihre Leitlinien zur guten wissenschaftlichen Praxis übernommen (DFG 2019: Leitlinie 13). Datenerhebung mit neuer Informationstechnologie und neue Informationstechnologie für Datensicherung und -management erlauben es in besonderer Weise, die Bevölkerung in den Forschungsprozess einzubinden. Ein Beispiel hierfür ist die Entwicklung von „Citizen Science", worunter der Einbezug der Bevölkerung in den gesamten Forschungsprozess von der Datenerhebung, über die Datenanalyse bis hin zur Interpretation von Forschungsergebnissen zu verstehen ist (Greshake Tzovaras et al. 2019). Aufgrund der hohen Nutzung von Smartphones und Wearables fallen tagtäglich in der Bevölkerung Datenschätze an, die in ein gemeinsames Datensicherungssystem eingespeist werden könnten. Ein Beispiel hierfür ist das Open Humans Projekt, bei dem neben Daten von Wearables auch auf andere Datenquellen (wie z. B. das Genom) zurückgegriffen wird (ebd. 2019). Dies erfordert flexible Datensicherungs- und Datenmanagementsysteme, bei denen Teilnehmende einerseits ihre Daten zur Verfügung stellen, andererseits Kontrolle über ihre eigenen Daten behalten und diese selbstständig verwalten können. Auch können Datensicherungssysteme entwickelt werden, bei denen Personen im Besitz ihrer Daten bleiben, wobei Rechenoperationen auf die bei den Personen gesicherten Daten zurückgreifen

(z. B. Lai et al. 2018[5]). Datensicherungs- und Datenmanagementsysteme für neue Informationstechnologie können diesbezüglich auf moderne Ansätze der Informationstechnik wie Cloud-Systeme zurückgreifen (z. B. Doukas und Maglogiannis 2011). Solche Systeme gehen über klassische Daten-Repositorien, in denen Daten in Forschungsdatenzentren archiviert werden, hinaus.

Aufgrund der rasanten Entwicklung im Rahmen der Informationstechnik und der Komplexität solcher Systeme können sie hier nicht im Detail behandelt werden. Aus den datenschutzrechtlichen, forschungsethischen und das Datenmanagement betreffenden Herausforderungen, die in den Abschnitten 4 und 5 behandelt wurden, ergeben sich jedoch allgemeine, systemübergreifende Herausforderungen. Diese betreffen nicht nur Internet-Sicherungssysteme, sondern in gleicher Weise die Datenspeicherung und das Datenmanagement in Repositorien von Forschungseinrichtungen und -datenzentren. Daraus leiten sich weitere Empfehlungen ab.

Empfehlungen zum Datenmanagement

1) Allgemeine **Standards für die Datensicherung**, die auch Interoperabilität sicherstellen, sollten weiterentwickelt werden.
2) Um die Qualität der Datenerfassung und -analyse bestimmen und Reanalysen angemessen durchführen zu können, sollten – wie bereits in Abschnitt 3.1 empfohlen – die Rohdaten sowie **alle Informationen über eingesetzte Geräte und weitere Datenverarbeitungsstrategien** (z. B. Algorithmen) archiviert und mit den Daten **zur Verfügung** gestellt werden.
3) Sollen Daten frei zugänglich, z. B. im Internet, zur Verfügung gestellt werden (z. B. in Open Repositories), muss sichergestellt werden, dass **eine Deanonymisierung nicht möglich** ist. Aufgrund der Vielzahl von Daten, die eine Deanonymiserung erleichtern, und der Unkenntnis darüber, inwieweit zukünftige datenanalytische Methoden weitere Möglichkeiten der Deanonymisierung eröffnen (siehe hierzu z. B. Rocher/Hendrickx/de Montjoye 2019), sollten solche Daten grundsätzlich nicht öffentlich zur Verfügung gestellt werden, es sei denn, Teilnehmende stimmen dem – nach Aufklärung über die Risiken – in einer informierten Einwilligungserklärung explizit zu.[6] Zu empfehlen ist die **Speicherung der Daten in Forschungsdatenzentren** mit limitiertem und geregeltem Datenzugriff vor Ort oder via Internet mit entsprechendem Passwort-Schutz. Die Passwörter könnten auch in den Forschungsdatenzentren verwaltet und nach Rücksprache mit den Autorinnen bzw. Autoren der Publikationen sowie mit vertraglicher Absicherung (Datennutzungsverträge, die Missbrauch ausschließen sollen) an die interessierten Forschenden herausgegeben werden.
4) **Datensicherung und -weiterverwertung** sollten in einer informierten **Einwilligungserklärung** geregelt werden. Hierzu kann auf die in Abschnitt 4 vorgestellten Verfahren, u. a. auch die **treuhänderische Verwaltung von Daten**, zurückgegriffen werden.
5) Strategien der Datenanalyse, die es ermöglichen, dass **Personen im Besitz ihrer Daten bleiben**, sollten weiterentwickelt werden. Rechenoperationen würden dann auf Daten zurückgreifen, die an verschiedenen Orten (bei den teilnehmenden Personen) gespeichert sind.

5 Die Daten werden in der Datenbank so verschlüsselt, dass zum Entschlüsseln immer das Passwort der nutzenden Person benötigt wird. Das Verfahren ist auch dann sicher, wenn die Datenbank gestohlen wird. Dies impliziert, dass selbst der Betreiber der Datenbank keinen Zugriff auf die Daten ohne Zustimmung der Studienteilnehmenden erhält.

6 Teilnehmende können z. B. über die folgende Seite sensibilisiert werden, wie einzigartig ihre persönlichen Daten sind: https://cpg.doc.ic.ac.uk/individual-risk

6 Literaturverzeichnis

Althoff, Tim; Rok Sosič, Jennifer L. Hicks, Abby C. King, Scott L. Delp und Jure Leskovec (2017): Large-scale physical activity data reveal worldwide activity inequality. Nature 547(7663), 336-339.

AERA [American Educational Research Association], APA [American Psychological Association] und NCME [National Council of Measurement in Education] (2014): Standards for educational and psychological testing. Washington, DC, AERA.

Apte, Aditi; Vijendra Ingole, Pallavi Lele, Andrew Marsh, Tathagata Bhattacharjee, Siddhivinayak Hirve, Harry Campbell, Harish Nair, Sarah Chan und Sanjay Juvekar (2019): Ethical considerations in the use of GPS-based movement tracking in health research - lessons from a care-seeking study in rural west India. Journal of Global Health 9(1), 010323. https://doi.org/10.7189/jogh.09.010323 (Zugriff am 27.01.2020).

Böhmer, Matthias; Brent Hecht, Johannes Schöning, Antonio Krüger und Gernot Bauer (2011): Falling asleep with Angry Birds, Facebook and Kindle: a large scale study on mobile application usage. In: Markus Bylund, Oskar Juhlin und Ylva Fernaeus (Hrsg.): Proceedings of the 13th Conference on Human-Computer Interaction with Mobile Devices and Services, Mobile HCI 2011, Stockholm, Sweden, August 30 - September 2, 2011. New York, ACM, 47-56. https://doi.org/10.1145/2037373.2037383 (Zugriff am 27.01.2020).

Brose, Annette und Ulrich Ebner-Priemer (2015): Ambulatory assessment in research on aging: Contemporary and future applications. Gerontology 61(4), 372-380. https://doi.org/10.1159/000371707 (Zugriff am 27.01.2020).

Brown, Nicolas A.; Andrew B. Blake und Ryne A. Sherman (2017): A snapshot of life as lived: Wearable cameras in social and personality psychological science. Social Psychological and Personality Science 8(5), 592-600.

Brown, Harriet R.; Peter Zeidman, Peter Smittenaar, Rick A. Adams, Fiona McNab, Robb B. Rutledge und Raymond J. Dolan (2014): Crowdsourcing for cognitive science–the utility of smartphones. PLOS ONE 9(7), e100662. https://doi.org/10.1371/journal.pone.0100662 (Zugriff am 27.01.2020).

Carter, Adrian; Jacki Liddle, Wayne Hall und Helen Chenery (2015): Mobile phones in research and treatment: Ethical guidelines and future directions. Journal of Medical Internet Research mHealth and uHealth 3(4), e95. https://doi.org/10.2196/mhealth.4538 (Zugriff am 27.01.2020).

Clemes, Stacy A. und Nuala K. Deans (2012): Presence and duration of reactivity to pedometers in adults. Medicine & Science in Sports & Exercise 44(6), 1097-1101. http://dx.doi.org//10.1249/MSS.0b013e318242a377 (Zugriff am 27.01.2020).

Deutscher Ethikrat (2018): Big Data und Gesundheit – Datensouveränität als informationelle Freiheitsgestaltung. Stellungnahme. Berlin, Deutscher Ethikrat. https://www.ethikrat.org/fileadmin/Publikationen/Stellungnahmen/deutsch/stellungnahme-big-data-und-gesundheit.pdf (Zugriff am 27.01.2020).

DFG [Deutsche Forschungsgemeinschaft] (2019): Leitlinien zur Sicherung guter wissenschaftlicher Praxis. Kodex. Bonn, Deutsche Forschungsgemeinschaft (DFG). https://www.dfg.de/download/pdf/foerderung/rechtliche_rahmenbedingungen/gute_wissenschaftliche_praxis/kodex_gwp.pdf (Zugriff am 27.01.2020).

Diehl, Manfred; Karen Hooker und Martin J. Sliwinski (Hrsg.) (2015): Handbook of intraindividual variability across the life span. New York, Routledge.

Doukas, Charalampos und Ilias Maglogiannis (2011): Managing wearable sensor data through cloud computing. 2011 IEEE Third International Conference on Cloud Computing Technology and Science. Athens, Greece, November 29 - December 1, 2011, 440-445. https://doi.org/10.1109/CloudCom.2011.65 (Zugriff am 27.01.2020).

Eid, Michael; Mario Gollwitzer und Manfred Schmitt (2017): Statistik und Forschungsmethoden. 5. Auflage, Weinheim, Beltz.

Eid, Michael und Katharina Schmidt (2014): Testtheorie und Testkonstruktion. Göttingen, Hogrefe.

Evenson, Kelly R.; Michelle M. Goto und Robert D. Furberg (2015): Systematic review of the validity and reliability of consumer-wearable activity trackers. International Journal of Behavioral Nutrition and Physical Activity 12(159). https://doi.org/10.1186/s12966-015-0314-1 (Zugriff am 27.01.2020).

Fahrenberg, Jochen und Michael Myrtek (Hrsg.) (1996): Ambulatory assessment. Computer-assisted psychological and psychophysiological methods in monitoring and field studies. Göttingen, Hogrefe.

Feng, Tiantian; Amrutha Nadarajan, Colin Vaz, Brandon Booth und Shrikanth Narayanan (2018): TILES audio recorder: an unobtrusive wearable solution to track audio activity. WearSys '18 Proceedings of the 4th ACM Workshop on Wearable Systems and Applications. 2018 Munich, Germany, June 10, 2018, 33-38. https://doi.org/10.1145/3211960.3211975 (Zugriff am 27.01.2020).

Georgiou, Konstantinos; Andreas V. Larentzakis, Nehal N. Khamis, Ghadah I. Alsuhaibani, Yasser A. Alaska und Elias J. Giallafos (2018): Can wearable devices accurately measure heart rate variability? A systematic review. Folia Med (Plovdiv) 60(1), 7-20. https://doi.org/10.2478/folmed-2018-0012 (Zugriff am 27.01.2020).

Göritz, Anja S. (2014): Incentive effects. In: Uwe Engel, Ben Jann, Peter Lynn, Annette Scherpenzeel und Patrick Sturgis (Hrsg.): Improving survey methods: Lessons from recent research. London, Routledge, 339-350.

Greshake Tzovaras, Bastian; Misha Angrist, Kevin Arvai, Mairi Dulaney, Vero Estrada-Galiñanes, Beau Gunderson, Tim Head, Dana Lewis, Oded Nov, Orit Shaer, Athina Tzovara, Jason Bobe und Mad Price Ball (2019): Open Humans: A platform for participant-centered research and personal data exploration. GigaScience 8(6), giz076. https://doi.org/10.1093/gigascience/giz076 (Zugriff am 27.01.2020).

Harari, Gabriella M.; Nicholas D. Lane, Rui Wang, Benjamin S. Crosier, Andrew T. Campbell und Samuel D. Gosling (2016): Using smartphones to collect behavioral data in psychological science: Opportunities, practical considerations, and challenges. Perspectives on Psychological Science 11(6), 838-854. https://doi.org/10.1177/1745691616650285 (Zugriff am 27.01.2020).

Harari, Gabriella M.; Sandrine R. Müller, Clemens Stachl, Rui Wang, Weichen Wang, Markus Bühner, Peter J. Rentfrow, Andrew T. Campbell und Samuel D. Gosling (2019): Sensing sociability: Individual differences in young adults' conversation, calling, texting, and app use behaviors in daily life. Journal of Personality and Social Psychology. Advance online publication, May 20, 2019. http://dx.doi.org/10.1037/pspp0000245 (Zugriff am 27.01.2020).

Houtveen, Jan H. und Eco J. C. de Geus (2009): Noninvasive psychophysiological ambulatory recordings: Study design and data-analysis strategies. European Psychologist 14(12), 132–141. http://dx.doi.org/10.1027/1016-9040.14.2.132 (Zugriff am 27.01.2020).

Johnson, Isaac L.; Subhasree Sengupta, Johannes Schöning und Brent Hecht (2016): The geography and importance of localness in geotagged social media. Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems (CHI '16). New York, NY, USA, ACM, 515-526. https://doi.org/10.1145/2858036.2858122 (Zugriff am 27.01.2020).

Kelly, Paul; Simon J. Marshall, Hannah Badland, Jacqueline Kerr, Melody Oliver, Aiden R. Doherty und Charlie Foster (2013): An ethical framework for automated, wearable cameras in health behavior research. American Journal of Preventive Medicine 4(3), 314-319. https://doi.org/10.1016/j.amepre.2012.11.006 (Zugriff am 27.01.2020).

Kiukkonen, Niko; Jan Blom, Oliviel Dousse, Daniel Gatica-Perez und Juha Laurila (2010): Towards rich mobile phone datasets: Lausanne data collection campaign. Proceedings of the International Conference on Pervasive Services. Berlin, ICPS, 68. http://publications.idiap.ch/downloads/papers/2010/Kiukkonen_ICPS,BERLIN,2010_2010.pdf (Zugriff am 27.01.2020).

Klenk, Juergen; Philip R. O. Payne, Rasu Shrestha und Margo Edmunds (2019): Open science and the future of data. In: Margo Edmunds, Christopher Hass und Erin Holve (Hrsg.): Consumer informatics and digital health. Solutions for health and health care. Basel, Springer International Publishing, 337-357. https://doi.org/10.1007/978-3-319-96906-0 (Zugriff am 27.01.2020).

Klucken, Jochen; Till Gladow, Johannes G. Hilgert, Marc Stamminger, Christian Weigand und Björn Eskofier (2019): „Wearables" in der Behandlung neurologischer Erkrankungen – wo stehen wir heute? Der Nervenarzt 90(8), 787–795. https://doi:10.1007/s00115-019-0753-z (Zugriff am 27.01.2020).

Kreuter, Frauke; Georg-Christoph Haas, Florian Keusch, Sebastian Bähr und Mark Trappmann (2018): Collecting survey and smartphone sensor data with an app: Opportunities and challenges around privacy and informed consent. Social Science Computer Review, OnlineFirst. https://doi.org/10.1177/0894439318816389 (Zugriff am 27.01.2020).

Lai, Russell W. F; Christoph Egger, Manuel Reinert, Sherman S. M. Chow, Matteo Maffei und Dominique Schröder (2018): Simple password-hardened encryption services. 27th USENIX Security Symposium (USENIX Security 18), Baltimore, MD, USA, August 15-17, 2018, USENIX Association, 1405-1421.

Langheinrich, Marc und Florian Schaub (2019): Privacy in mobile and pervasive computing. San Rafael, California (USA), Morgan & Claypool Publishers. https://doi.org/10.2200/S00882ED1V01Y201810MPC013 (Zugriff am 27.01.2020).

Linas, Beth S.; Andrew Genz, Ryan P. Westergaard, Larry W. Chang, Robert C. Bollinger, Carl Latkin und Gregory D. Kirk (2016): Ecological momentary assessment of illicit drug use compared to biological and self-reported methods. Journal of Medical Internet Research mHealth and uHealth 4(1), e27. https://doi.org/10.2196/mhealth.4470 (Zugriff am 27.01.2020).

Mainali, Pradip; Carlton Shepherd und Fabien A. P. Petitcolas (2019): Privacy-enhancing context authentication from location-sensitive data. In Proceedings of the 14th International Conference on Availability, Reliability and Securit, 87-97. Osaka, ACM Press. https://doi.org/10.1145/3339252.3340334 (Zugriff am 27.01.2020).

Mehl, Matthias R. (2017): The Electronically Activated Recorder (EAR): A method for the naturalistic observation of daily social behavior. Current directions in psychological science 26(2), 184-190. https://doi.org/10.1177/0963721416680611 (Zugriff am 27.01.2020).

Messick, Samuel (1989): Validity. In: Robert L. Linn (Hg.): Educational measurement. 3. Auflage, New York, Collier Macmillan Publishers, 13-103.

Messick, Samuel (1995): Validity of psychological assessment: Validation of inferences from persons' responses and performances as scientific inquiry into score meaning. American Psychologist 50(9), 741-749. http://dx.doi.org/10.1037/0003-066X.50.9.741 (Zugriff am 27.01.2020).

Miller, Geoffrey (2012): The smartphone psychology manifesto. Perspectives on Psychological Science 7(3), 221-237. https://doi.org/10.1177/1745691612441215 (Zugriff am 27.01.2020).

Mischel, Walter und Yuichi Shoda (1995): A cognitive-affective theory of personality: Reconceptualising situations, dispositions, dynamics, and invariance in personality structure. Psychological Review 102(2), 246-268. http://dx.doi.org/10.1037/0033-295X.102.2.246 (Zugriff am 27.01.2020).

Mezghani, Emna; Ernesto Exposito, Khalil Drira, Marcos Da Silveira und Cédric Pruski (2015): A semantic big data platform for integrating heterogeneous wearable data in healthcare. Journal of Medical Systems 39, 185. https://doi.org/10.1007/s10916-015-0344-x (Zugriff am 27.01.2020).

Muaaz, Muhammad und René Mayrhofer (2017): Smartphone-based gait recognition: From authentication to imitation. IEEE Transactions on Mobile Computing 16 (11), 3209-3221. https://doi.org/10.1109/TMC.2017.2686855 (Zugriff am 27.01.2020).

Naor, Moni und Moti Yung (1989): Universal one-way hash functions and their cryptographic applications. STOC '89 Proceedings of the twenty-first annual ACM symposium on Theory of computing. Seattle, Washington (USA), ACM, 33-43. https://doi.org/10.1145/73007.73011 (Zugriff am 27.01.2020).

Narayanan, Shrikanth und Panayiotis G. Georgiou (2013): Behavioral signal processing: Deriving human behavioral informatics from speech and language. Proceedings of the IEEE 101(5), 1203–1233. https://doi.org/10.1109/JPROC.2012.2236291 (Zugriff am 27.01.2020).

Ochoa, Carlos; Carlos Bort und Josep Miquel Porcar (2018): Who is who with behavioural data. An algorithm to attribute the device's navigation to users sharing the same device. Frontiers of Marketing Data Science Journal 1, 43-62.

Peake, Jonathan M.; Graham Kerr und John P. Sullivan (2018): A critical review of consumer wearables, mobile applications, and equipment for providing biofeedback, monitoring stress, and sleep in physically active populations. Frontiers in Physiology 9, 743. https://doi.org/10.3389/fphys.2018.00743 (Zugriff am 27.01.2020).

Prince, Stéphanie A; Kristi B. Adamo, Meghan E. Hamel, Jill Hardt, Sarah Connor Gorber und Mark Tremblay (2008): A comparison of direct versus self-report measures for assessing physical activity in adults: A systematic review. International Journal of Behavioral Nutrition and Physical Activity 5(1), 56. https://dx.doi.org/10.1186/1479-5868-5-56 (Zugriff am 27.01.2020).

Rammstedt, Beatrice; Constanze Beierlein, Elmar Brähler, Michael Eid, Johannes Hartig, Martin Kersting, Stefan Liebig, Josef Lukas, Anne-Kathrin Mayer, Natalja Menold, Jürgen Schupp und Erich Weichselgartner (2014): Qualitätsstandards zur Entwicklung, Anwendung und Bewertung von Messinstrumenten in der sozialwissenschaftlichen Umfrageforschung. Schmollers Jahrbuch – Zeitschrift für Wirtschaft- und Sozialwissenschaften 134(4), 517-546. Auch als RatSWD Working Paper erschienen (RatSWD Working Paper 230/2014).

Ranjan, Juhi und Kamin Whitehouse (2015): Object hallmarks: Identifying object users using wearable wrist sensors. Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing. Osaka, ACM Press, 51-61. https://doi.org/10.1145/2750858.2804263 (Zugriff am 27.01.2020).

Ranjan, Yatharth; Zulqarnain Rashid, Callum Stewart, Pauline Conde, Mark Begale, Denny Verbeeck, Sebastian Boettcher, The Hyve, Richard Dobson, Amos Folarin und The RADAR-CNS Consortium (2019): RADAR-base: An open source mHealth platform for collecting, monitoring and analyzing data using sensors, wearables, and mobile devices. Journal of Medical Internet Research mHealth and uHealth 7(8), e11734. https://doi.org/10.2196/11734 (Zugriff am 27.01.2020).

RatSWD [Rat für Sozial- und Wirtschaftsdaten] (2019): Big Data in den Sozial-, Wirtschafts- und Verhaltenswissenschaften: Datenzugang und Forschungsdatenmanagement. RatSWD Output 4(6). Berlin, Rat für Sozial- und Wirtschaftsdaten (RatSWD). https://doi.org/10.17620/02671.39 (Zugriff am 27.01.2020).

RfII [Rat für Informationsinfrastrukturen] (2019): Herausforderung Datenqualität – Empfehlungen zur Zukunftsfähigkeit von Forschung im digitalen Wandel. Göttingen, Rat für Informationsinfrastrukturen. http://www.rfii.de/?p=4043 (Zugriff am 27.01.2020).

Robbins, Megan L. (2017): Practical suggestions for legal and ethical concerns with social environment sampling methods. Social Psychological and Personality Science 8(5), 573-580. https://doi.org/10.1177/1948550617699253 (Zugriff am 27.01.2020).

Rocher, Luc; Julien M. Hendrickx und Yves-Alexandre de Montjoye (2019): Estimating the success of re-identifications in incomplete datasets using generative models. Nature Communications 10(1), 3069. https://doi.org/10.1038/s41467-019-10933-3 (Zugriff am 27.01.2020).

Salles, Gil F.; Claudia R. L. Cardoso und Elizabeth S. Muxfeldt (2008): Prognostic influence of office and ambulatory blood pressures in resistant hypertension. Archives of Internal Medicine, 168(21), 2340-2346. https://doi.org/10.1001/archinte.168.21.2340 (Zugriff am 27.01.2020).

Schmidt, Philip; Attila Reiss, Robert Duerichen und Kristof Van Laerhoven (2018): Wearable affect and stress recognition: A review. https://arxiv.org/abs/1811.08854 (Zugriff am 27.01.2020).

Schwarz, Nobert (2012): Why researchers should think "real-time": A cognitive rationale. In: Matthias R. Mehl und Tamlin S. Connor (Hrsg.): Handbook of Research Methods for Studying Daily Life. New York, Guilford Press, 22-42.

Schupp, Jürgen und Christof Wolf (Hrsg.) (2015): Nonresponse Bias: Qualitätssicherung sozialwissenschaftlicher Umfragen. Berlin, Springer-Verlag.

Shcherbina, Anna; C. Mikael Mattsson, Daryl Waggott, Heidi Salisbury, Jeffrey W. Christle, Trevor Hastie, Matthew T. Wheeler und Euan A. Ashley (2017): Accuracy in wrist-worn, sensor-based measurements of heart rate and energy expenditure in diverse cohort. Journal of Personalized Medicine 7(2), 3. https://doi.org/10.3390/jpm7020003 (Zugriff am 27.01.2020).

Shrout, Patrick E.; Gertraud Stadler, Sean P. Lane, M. Joy McClure, Grace L. Jackson, Frederick D. Clavél, Masumi Iida, Marci E. J. Gleason, Joy H. Xu und Niall Bolger (2018): Initial elevation bias in subjective reports. Proceedings of the National Academy of Sciences 115(1), E15-E23. https://doi.org/10.1073/pnas.1712277115 (Zugriff am 27.01.2020).

Sinibaldi, Jennifer; Mark Trappmann und Frauke Kreuter (2014): Which is the better investment for nonresponse adjustment: Purchasing commercial auxiliary data or collecting interviewer observations? Public Opinion Quarterly 78(2), 440–473. https://doi.org/10.1093/poq/nfu003 (Zugriff am 27.01.2020).

Stergiou, George; Anastasios Kollias, Gianfranco Parati und Eoin O'Brien (2018): Office blood pressure measaurement. The weak cornerstone of hypertension diagnosis. Hypertension 71(5), 813-815. https://doi.org/10.1161/HYPERTENSIONAHA.118.10850 (Zugriff am 27.01.2020).

Stone, Arthur; Joan Broderick, Joseph Schwartz, Saul Shiffman, Leighann Litcher-Kelly und Pamela Calvanese (2003): Intensive momentary reporting of pain with an electronic diary: reactivity, compliance, and patient satisfaction. Pain 104(1-2), 343-351. https://doi.org/10.1016/S0304-3959(03)00040-X (Zugriff am 27.01.2020).

Strübing, Jörg; Stefan Hirschauer, Ruth Ayaß, Uwe Krähnke und Thomas Scheffer (2018): Gütekriterien qualitativer Sozialforschung. Ein Diskussionsanstoß. Zeitschrift für Soziologie 47(2), 83-100. https://doi.org/10.1515/zfsoz-2018-1006 (Zugriff am 27.01.2020).

Tost, Heike; Markus Reichert, Urs Braun, Iris Reinhard, Robin Peters, Sven Lautenbach, Andreas Hoell, Emanuel Schwarz, Ulrich W. Ebner-Priemer, Alexander Zipf und Andreas Meyer-Lindenberg (2019): Brain circuitry underlying the real-life effect of urban green space on emotional well-being. Nature Neuroscience 22(9), 1389-1393. https://doi.org/10.1038/s41593-019-0451-y (Zugriff am 27.01.2020).

Trull, Timothy J. und Ulrich W. Ebner-Priemer (2013): Ambulatory assessment. Annual review of clinical psychology 9, 151-176. https://doi.org/10.1146/annurev-clinpsy-050212-185510 (Zugriff am 27.01.2020).

West, Brady T. (2013): An examination of the quality and utility of interviewer observations in the National Survey of Family Growth. Journal of the Royal Statistical Society: Series A. Statistics in Society 176(1), 211-225. https://doi.org/10.1111/j.1467-985X.2012.01038.x (Zugriff am 27.01.2020).

Wyatt, Danny; Tanzeem Choudhury, Jeff Bilmes und James A. Kitts (2011): Inferring colocation and conversation networks from privacy-sensitive audio with implications for computational social science. ACM Transactions on Intelligent Systems and Technology (TIST) 2(1), 7. https://doi.org/10.1145/1889681.1889688 (Zugriff am 27.01.2020).

Yetisen, Ali K.; Juan Leonardo Martinez‐Hurtado, Barış Ünal, Ali Khademhosseini und Haider Butt (2018): Wearables in medicine. Advanced Materials 30(33), 1706910. https://doi.org/10.1002/adma.201706910 (Zugriff am 27.01.2020).

Mitwirkende bei der Erstellung

Mitglieder der AG Datenerhebung mit neuer Informationstechnologie

Prof. Dr. Thomas K. Bauer
Ruhr-Universität Bochum, RWI – Leibniz-Institut für Wirtschaftsforschung

Prof. Dr. Ulrich Ebner-Priemer
Karlsruher Institut für Technologie (KIT)

Prof. Dr. Michael Eid, *Vorsitz der AG*
Freie Universität Berlin

Prof. Dr. Anja S. Göritz
Albert-Ludwigs-Universität Freiburg

Dr. Cornelia Lange
Robert Koch-Institut (RKI)

Prof. Dr. Kai Maaz
Goethe-Universität Frankfurt, DIPF – Leibniz-Institut für Bildungsforschung und Bildungsinformation

Elke Nagel
Statistisches Bundesamt (Destatis)

Bertram Raum
Datenschutz-Experte

Dr. David Richter
Sozio-oekonomisches Panel (SOEP) am Deutschen Institut für Wirtschaftsforschung (DIW Berlin)

Prof. Dr. Mark Trappmann
Institut für Arbeitsmarkt- und Berufsforschung (IAB) der Bundesagentur für Arbeit (BA),
Otto-Friedrich-Universität Bamberg

Konsultation

Prof. Dr. Bernad Batinic
Johannes Kepler Universität Linz

Prof. Dr. Peter Dabrock
Deutscher Ethikrat

Prof. Dr. Eco de Geus
Vrije Universiteit Amsterdam

Prof. Dr. Björn Eskofier
Friedrich-Alexander-Universität Erlangen-Nürnberg

Prof. Matthias Mehl, Ph.D.
University of Arizona

Prof. Dr. Johannes Schöning
Universität Bremen

Prof. Kristof Van Laerhoven, Ph.D.
Universität Siegen

Prof. Dr. Cornelia Wrzus
Universität Heidelberg

Geschäftsstelle RatSWD

Dr. Mathias Bug

Dr. Tim Deeken

Dr. Nora Dörrenbächer

Impressum

Herausgeber:
Rat für Sozial- und Wirtschaftsdaten (RatSWD)
Rungestr. 9
10179 Berlin
office@ratswd.de
https://www.ratswd.de

Redaktion:
Dr. Mathias Bug, Dr. Nora Dörrenbächer, Lea Salathé, Susanne Zindler

Gestaltung/Satz:
Claudia Kreutz

Icons:
made by Freepik from https://www.flaticon.com
Font Awesome, https://fontawesome.com (angepasst)

Berlin, Februar 2020

RatSWD Output:
Die RatSWD Output Series dokumentiert die Arbeit des RatSWD in seiner 6. Berufungsperiode (2017–2020). In ihr werden seine Stellungnahmen und Empfehlungen veröffentlicht und auf diesem Weg einer breiten Leserschaft zugänglich gemacht.

Das diesem Bericht zu Grunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung (BMBF) unter dem Förderkennzeichen 01UW1802 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt, sofern nicht anders ausgewiesen, beim RatSWD.

doi: 10.17620/02671.47

Zitationsvorschlag:

RatSWD [Rat für Sozial- und Wirtschaftsdaten] (2020): Datenerhebung mit neuer Informationstechnologie. Empfehlungen zu Datenqualität und -management, Forschungsethik und Datenschutz. RatSWD Output 6 (6). Berlin, Rat für Sozial- und Wirtschaftsdaten (RatSWD). https://doi.org/10.17620/02671.47.

Der Rat für Sozial- und Wirtschaftsdaten (RatSWD) berät seit 2004 die Bundesregierung und die Regierungen der Länder in Fragen der Forschungsdateninfrastruktur für die empirischen Sozial-, Verhaltens- und Wirtschaftswissenschaften. Im RatSWD arbeiten acht durch Wahl legitimierte Vertreterinnen und Vertreter der sozial-, verhaltens- und wirtschaftswissenschaftlichen Fachdisziplinen mit acht Vertreterinnen und Vertretern der wichtigsten Datenproduzenten zusammen.

Er versteht sich als institutionalisiertes Forum des Dialoges zwischen Wissenschaft und Datenproduzenten und erarbeitet Empfehlungen und Stellungnahmen. Der RatSWD engagiert sich für eine Infrastruktur, die der Wissenschaft einen breiten, flexiblen und sicheren Datenzugang ermöglicht. Solche Daten werden von staatlichen, wissenschaftsgetragenen und privatwirtschaftlichen Akteuren bereitgestellt. Der RatSWD hat 34 Forschungsdatenzentren akkreditiert, deren Kooperationen er fördert.

www.ratswd.de