

Digitale Phänotypisierung in der Psychologie – ein Quantensprung in der psychologischen Forschung?

Harald Baumeister¹, Patricia Garatva¹, Rüdiger Pryss², Timo Ropinski³ und Christian Montag⁴

¹Abteilung für Klinische Psychologie und Psychotherapie, Institut für Psychologie und Pädagogik, Universität Ulm, Deutschland

²Institut für Klinische Epidemiologie und Biometrie, Universität Würzburg, Deutschland

³Arbeitsgruppe Visual Computing, Institut für Medieninformatik, Universität Ulm, Deutschland

⁴Abteilung für Molekulare Psychologie, Institut für Psychologie und Pädagogik, Universität Ulm, Deutschland

Zusammenfassung: Digitale Phänotypisierung stellt einen neuen, leistungsstarken Ansatz zur Realisierung psychodiagnostischer Aufgaben in vielen Bereichen der Psychologie und Medizin dar. Die Grundidee besteht aus der Nutzung digitaler Spuren aus dem Alltag, um deren Vorhersagekraft für verschiedenste Anwendungsmöglichkeiten zu überprüfen und zu nutzen. Voraussetzungen für eine erfolgreiche Umsetzung sind elaborierte Smart Sensing Ansätze sowie Big Data-basierte Extraktions- (Data Mining) und Machine Learning-basierte Analyseverfahren. Erste empirische Studien verdeutlichen das hohe Potential, aber auch die forschungsmethodischen sowie ethischen und rechtlichen Herausforderungen, um über korrelative Zufallsbefunde hinaus belastbare Befunde zu gewinnen. Hierbei müssen rechtliche und ethische Richtlinien sicherstellen, dass die Erkenntnisse in einer für Einzelne und die Gesellschaft als Ganzes wünschenswerten Weise genutzt werden. Für die Psychologie als Lehr- und Forschungsdomäne bieten sich durch Digitale Phänotypisierung vielfältige Möglichkeiten, die zum einen eine gelebte Zusammenarbeit verschiedener Fachbereiche und zum anderen auch curriculare Erweiterungen erfordern. Die vorliegende narrative Übersicht bietet eine theoretische, nicht-technische Einführung in das Forschungsfeld der Digitalen Phänotypisierung, mit ersten empirischen Befunden sowie einer Diskussion der Möglichkeiten und Grenzen sowie notwendigen Handlungsfeldern.

Schlüsselwörter: Digitale Phänotypisierung, Smart Sensing, Ambulatory Assessment, Künstliche Intelligenz

Digital Phenotyping in Psychology: A Quantum Leap for Psychological Research?

Abstract: Digital phenotyping constitutes a new and powerful psychodiagnostic approach in many areas of psychology and medicine. The basic idea behind digital phenotyping is using digital traces gathered in everyday life to check their predictive potential. Digital traces may reveal predictive power capabilities for a wide range of applications. The prerequisites for a successful implementation are elaborated smart sensing approaches, big data-based extraction (data mining), and machine learning-based analysis methods. Initial empirical studies illustrate the high potential but also the research methodological as well as ethical and legal challenges to establishing reliable findings beyond random correlative results. In particular, legal and ethical guidelines need to set the siderails, ensuring that the findings are utilized in ways desirable to both individuals and society. To conclude, digital phenotyping offers a wide range of opportunities for psychology as a research and teaching domain, which, on the one hand, strives for lived collaboration between specialized fields, and, on the other hand, wants curricular extensions. The present narrative review provides a theoretical and nontechnical introduction to the research field of digital phenotyping, initial empirical findings, a discussion of its possibilities and limitations, and recommendations for action areas.

Keywords: digital phenotyping, smart sensing, ambulatory assessment, artificial intelligence

Einführung in Digitale Phänotypisierung

Digitalisierung bestimmt derzeit nicht nur den gesellschaftlichen Diskurs (Hinds & Joinson, 2018), sondern findet seine Entsprechung auch in der Neuausrichtung oder zumindest Ergänzung verschiedener wissenschaftlicher

Felder, nicht zuletzt in der psychologischen Forschung. An der Spitze dieses Trends steht die Nutzung von Smart Device Technologien, wie beispielsweise Smartphones oder Gesundheitsarmbänder, in vielfältigen Forschungsbereichen der Psychologie (Baumeister & Montag, 2019). Diese bieten mit ihrer eingebauten Sensorik einen deutlich erweiterten Zugang zu vielen relevanten psychologischen, biologischen und verhaltensbezogenen Variablen,

einschließlich des Kommunikationsverhaltens und psychophysiologischer Daten (Montag & Elhai, 2019). Dies ermöglicht es, den Menschen im Alltag kontinuierlich zu untersuchen (Mohr, Zhang & Schueller, 2017).

Obwohl das Smartphone aufgrund seiner Allgegenwärtigkeit in der Bevölkerung und der eingebauten Sensorik (Laport-López, Serrano, Bajo & Campbell, 2020) zweifelsohne den offensichtlichsten „Game Changer“ darstellt (Miller, 2012), stellt es nur einen kleinen Teil einer größeren Entwicklung hin zum Internet der Dinge dar, bei dem von Haushaltsgeräten bis zum Auto alles mit dem Internet verbunden sein wird (Montag & Diefenbach, 2018). Die menschliche Interaktion hinterlässt bei all diesen mit dem Internet verbundenen Geräten zunehmend umfangreiche digitale Spuren, die wissenschaftlich genutzt werden können, um bio-psycho-soziale Aspekte des menschlichen Verhaltens und Erlebens abzubilden und vorherzusagen, die von der Persönlichkeit bis hin zu klinischen Zuständen und Verläufen der physischen und psychischen Gesundheit reichen (Baumeister & Montag, 2019). Die Kombination aus Nutzung von technologischen Ansätzen und traditionell psychologischer Ansätze stellt das relativ neue Forschungsfeld der Psychoinformatik dar (Montag, Duke & Markowitz, 2016). Dabei bildet die Digitale Phänotypisierung einen prominenten Vertreter dieses Forschungsfeldes (Baumeister & Montag, 2019). Unter Digitaler Phänotypisierung versteht man dabei die Nutzung digitaler Daten zur Vorhersage menschlichen Erlebens und Verhaltens. Die Bezeichnung Digitale Phänotypisierung ist als Erweiterung des aus der Genetik stammenden Begriffs des Phänotyps, als Menge aller Merkmale des betreffenden Organismus zu betrachten (Baumeister & Montag, 2019; Jain, Powers, Hawkins & Brownstein, 2015). Smart Sensing beschreibt in diesem Kontext die Sammlung und Analyse einer großen Datenmenge, die vor allem passiv im Hintergrund von digitalen Geräten abläuft (wobei aber auch aktiv Daten generiert werden können) (Torous, Kiang, Lorme & Onnela, 2016). In den letzten Jahren hat das Forschungsinteresse in diesem Feld stark zugenommen, wobei sich die Zahl der Veröffentlichungen von 2014 bis 2017 fast verdoppelt hat (Trifan, Oliveira & Oliveira, 2019).

Ziel der vorliegenden narrativen Übersicht ist es, eine Einführung in das Forschungsfeld der Digitalen Phänotypisierung zu geben. Über die wichtigsten technischen Begrifflichkeiten informieren wir im Überblick, vertiefende Literatur hierzu siehe u.a. Dey (2016) und Mohr et al. (2017). Empirische Befunde bieten beispielhaft einen Eindruck zum potentiellen Nutzen des Forschungsfeldes sowie zu methodischen Herausforderungen und Grenzen. Abschließend werden potenziell weiterführende Forschungsansätze erörtert.

Digitale Phänotypisierung und damit verbundene wichtige Bereiche und Begrifflichkeiten

Die Systematisierung dieses dynamischen und sich schnell entwickelnden Forschungsgebietes ist eine Herausforderung, da die technologische Entwicklung in verschiedenen und nicht miteinander verbundenen Forschungsbereichen sehr schnell voranschreitet (Baumeister & Montag, 2019). Auch wenn die spezifischen Ansätze unterschiedlich sein mögen, kann Baumeister & Montag (2019) folgend ein erster Rahmen für Digitale Phänotypisierung in der Psychologie vorgeschlagen werden (Abbildung 1).

Dabei werden eine Vielzahl von Schlagwörtern wie Ambulatory Assessment, Smart Sensing und Begriffe der mit der Digitalen Phänotypisierung verbundenen künstlich-intelligenten (KI-) Datenanalyseansätzen wie Big Data, Data Mining, Machine und Deep Learning verwendet, um die gesellschaftlichen, wirtschaftlichen und nicht zuletzt wissenschaftlichen Potentiale der Digitalen Phänotypisierung für das Leben der Menschen und die Gesellschaft als Ganzes auszudrücken (Baumeister & Montag, 2019). Im Folgenden sollen zunächst die Bereiche des Ambulatory Assessment und Smart Sensings sowie deren Methodik und Abgrenzung voneinander erläutert werden. Im Abschnitt danach werden KI-Grundlagen (Big Data, Data Mining, Machine und Deep Learning Algorithmen) beleuchtet.

Ambulatory Assessment

Unter Ambulatory Assessment versteht man eine Forschungs- bzw. Assessmentstrategie, die das Ziel hat, psychologische und physiologische Parameter, Verhaltensweisen sowie das Erleben von Personen in deren natürlichem Lebensumfeld innerhalb eines situativen Kontexts und in Echtzeit hypothesengeleitet zu erfassen (Fahrenberg, 1996; 2001; Fahrenberg, Myrtek, Pawlik & Perez, 2007; Timmons et al., 2017; Trull & Ebner-Priemer, 2013). Dies geschieht in der Regel durch wiederholte kurze Befragungen (aktive Datenquellen, wie z.B., Selbstbericht, Fremdbbericht / Ratings), wodurch Daten kontinuierlich erfasst werden können (van Roekel, Keijsers & Chung, 2019). Seit den 1980er Jahren wurden dazu tragbare computer-unterstützte Messsysteme entwickelt, welche in der Medizin schnell Anwendung fanden (z.B. ambulante 24-Stunden-Überwachung des Blutdrucks) (Fahrenberg et al., 2007). In der Psychologie wurde es zunächst vor allem als Alternative zur Psychodiagnostik gesehen, welche traditionell mit Stift und Papier durchgeführt wurde (Fahrenberg et al., 2007; Shiffman, Stone & Hufford, 2008). Dank




Abbildung 1. Digitales Phänotypisierungsframework (modifiziert nach Baumeister & Montag, 2019).

des technologischen Fortschritts können Ambulatory Assessment-Studien heute mit Smartphones oder anderen tragbaren Geräten (sogenannten Wearables, z.B. Smartwatches) und darauf installierter Apps durchgeführt werden (de Vries, Baselmans & Bartels, 2021). Folglich kann die Strategie des Ambulatory Assessments inzwischen als komplementärer Ansatz oder als „add-on“ zur konventionellen Psychodiagnostik gesehen werden (vgl. Schwarz, 2008).

Das Ambulatory Assessment (Fahrenberg, 1996; Fahrenberg et al., 2007) umfasst eine Sammlung an Methoden aus verschiedenen Disziplinen (Psychologie, Medizin, Informatik usw.), wie z.B. die Experience Sampling Method (ESM; Csikszentmihalyi & Larson, 2014) und das Ecological Momentary Assessment (EMA; Stone & Shiffman, 1994). All diese Methoden haben im Kern gemein, dass sie das Ziel haben, aktuelles Verhalten und Erfahrungen der Teilnehmenden zu dem Zeitpunkt und an dem Ort, an welchem das zu beobachtende Verhalten oder Ereignis tatsächlich gerade stattfindet, zu erfassen (de Vries et al., 2021; Shiffman et al., 2008; Timmons et al., 2017). Einen historischen Überblick über die Entwicklung der verschiedenen Methoden – die als Vorläufer der Digitalen Phänotypisierung oder auch als übergeordneter Forschungsrahmen angesehen werden können – finden Sie bei Wilhelm, Perrez & Pawlik (2012). Im Folgenden werden zentrale Vorteile dieser Forschungsmethodik, die auch für den spezifischen Bereich der Digitalen Phänotypisierung von Relevanz sind, erläutert (Trull & Ebner-Priemer, 2009):

1) *(nahezu) Echtzeit-Erfassung (near real-time assessment)*: Die Daten werden in Situationen gesammelt, in denen sie tatsächlich auftreten, anstatt zu versuchen, Verhaltensweisen im Labor zu erzeugen oder die Teilnehmenden zu befragen (Timmons et al., 2017). Bei klassischen Selbstberichtsfragebögen auf Papier sind die Antworten immer retrospektiv und unterliegen Verzerrungen (Shiffman et al., 2008). Zudem kann dadurch Feedback in Echtzeit rückgemeldet werden (Ebner-Priemer, Kubiak & Pawlik, 2009). Trotzdem muss von beinahe oder nahezu Echtzeit-Erfassung gesprochen werden, da auch EMA mit retrospektiven Einschätzungen arbeitet (z.B. ist die EMA-Frage „Wie haben Sie geschlafen?“ mit einer retrospektiven Einschätzung verbunden – trotzdem ist diese zeitlich näher an dem Echtzeit-Erlebnis als dies ein klassischer Selbstberichtsfragebogen auf Papier zumeist sein kann).

2) *Assessments im realen Leben*: Die Erfassung der Daten im natürlichen Lebensumfeld und Alltag der Personen erhöht die ökologische Validität der Daten, also deren Gültigkeit und Verallgemeinerbarkeit (Ebner-Priemer et al., 2009; Shiffman et al., 2008; van Roekel et al., 2019).

3) *Wiederholte und multimodale Assessments*: Durch die wiederholten Messungen kann ein Verhalten kontinuierlich und über verschiedene Situationen hinweg erfasst werden (Shiffman et al., 2008). Zudem erlaubt es das Ambulatory Assessment, psychologische, physiologische, verhaltensbezogene und kontextspezifische Daten einzuschließen, wodurch wir einen noch stärkeren Einblick in individuelle Verhaltensweisen erlangen können (Ebner-Priemer & Trull, 2009; Shiffman et al., 2008). Dies führt jedoch zu Herausforderungen bei der Datenanalyse (siehe

hierzu weiterführende Informationen unter „KI-Grundlagen“). Durch das wiederholte Assessment werden auch Verlaufsanalysen einzelner Personen über die Zeit möglich (within-subject Perspektive, z.B. mittels Trajectory Analyses (Reichert et al. 2021)).

Nachteile des Ambulatory Assessment sind hingegen, dass die Teilnehmenden ihren Tag regelmäßig unterbrechen, um die Messungen durchzuführen (Robbins & Kubiak, 2014). Es kann unangenehm oder störend sein, eine aktuelle Tätigkeit zu unterbrechen, um einen Fragebogen auszufüllen (Robbins & Kubiak, 2014). Dies kann eine Belastung für die Teilnehmenden darstellen und die Studienadhärenz reduzieren (Robbins & Kubiak, 2014).

Während es beim Ambulatory Assessment, insbesondere bei EMA, (je nach Definition) um die *aktive* mobile Datenerfassung im Alltag geht, erweitert Digitale Phänotypisierung diesen Ansatz um die *passive* Datenerfassung (Passive Sensing), welche keine aktive Beteiligung von Nutzenden erfordert (z.B. durch die Erfassung von GPS-Daten im Hintergrund des Smartphones). Zudem ermöglicht es die Erfassung von Metadaten, einer Kombination aus passiven und aktiven Daten, wie z.B. die Zeit, die benötigt wird, um die EMA-Umfrage zu beenden (Benoit, Onyeaka, Keshavan & Torous, 2020; Majumder & Deen, 2019). Ein Beispiel für die Kombination von Digitaler Phänotypisierung und EMA liefern Messner et al. (2019): Sie untersuchten, ob es einen Zusammenhang zwischen dem Smartphone-Nutzungsverhalten (erfasst mittels Passive Sensing) und dem selbstberichteten Wohlbefinden (Stresslevel, Antrieb, Stimmung; erfasst durch EMA-Befragungen) gibt. Durch die Verwendung der INSIGHTS-App bei 157 Studierenden über acht Wochen hinweg konnten sie einen negativen Zusammenhang zwischen dem Smartphone-Nutzungsverhalten (z.B. Gesamtnutzungszeit, Gesprächsdauer) und dem selbstberichteten Stress, Antrieb und der Stimmung feststellen (Messner et al., 2019).

Zusammenfassend kann gesagt werden, dass die bereits erwähnten Vorteile des Ambulatory Assessments gleichermaßen für Digitale Phänotypisierung gelten, wobei die Nachteile (die Unterbrechung im Alltag und die damit einhergehende Belastung und sinkende Bereitschaft) damit überwunden werden können. Durch den unaufdringlichen Charakter (durch die passive Datensammlung im Hintergrund) der Digitalen Phänotypisierung können damit über einen langen Zeitraum hinweg Daten gesammelt werden (Garatva et al., 2023). Zudem werden durch die Allgegenwärtigkeit von mobilen Geräten (und darin eingebetteten Sensoren) große Stichproben möglich und auch Risikopopulationen können erreicht werden (Messner et al., 2019; Mohr et al., 2017). Gleichzeitig weist der Gegenstandsbereich neue Herausforderungen und Grenzen auf, die im weiteren Verlauf dieser Übersicht ausge-

führt werden. Montag und Elhai (2019) betonen weiterhin die Wichtigkeit der Nutzung von Selbstberichtfragebögen, da manche Informationen über eine Person nur über deren eigene Einschätzung und Introspektionsfähigkeit zugänglich sind (z.B. subjektives Erleben). Eine neue Arbeit von Montag, Dagum, Hall & Elhai (2021) beschäftigt sich in diesem Zusammenhang auch mit der Rolle psychologischer Fragebögen in einem Zeitalter des Internet der Dinge.

Smart Sensing

Smart Sensing wird oft durch das Gerät spezifiziert, das die mobilen Sensordaten liefert (Mobile Sensing), d.h. Smart Sensing-Geräte, wie Smartphone, Smartwatch, Smart-Wearables, und durch die Daten, die ein Smart Sensing-Gerät erfasst, z.B. Sprach- und Stimmsensorik, Verhaltenssensing, Biosensorik sowie Bild- und Videosensorik (vgl. Abbildung 1) (Baumeister & Montag, 2019; Garatva et al., 2023). Bei der Nutzung von diesen digitalen Geräten hinterlassen wir digitale „Fußabdrücke“, die die Datenbasis liefern, um unsere Eigenschaften, Zustände, Einstellungen, Kognitionen und Emotionen „abzuschätzen“ (sensing), zu analysieren und je nach Nutzungsziel weiter zu verarbeiten (Lydon-Staley, Barnett, Satterthwaite & Bassett, 2019; Martinez-Martin, Insel, Dagum, Greely & Cho, 2018; Montag et al., 2016).

Laport-López et al. (2020) differenzieren in Bezug auf Mobile Sensing zwischen a) Personen-bezogenes (*people-centric*) und Umwelt-bezogenes (*environmental-centric*) Sensing, b) interaktives (*participatory*) und opportunistisches (*opportunistic*) Sensing sowie c) persönliches (*personal*), soziales (*social*) und öffentliches (*public*) Sensing. Der in der wissenschaftlichen Literatur am häufigsten beschriebene Nutzungsfall stellt ein Personen-bezogenes, persönliches, wahlweise interaktives oder opportunistisches Sensing dar (Laport-López et al., 2020).

Der für die Psychologie sicherlich zentrale Bereich des Personen-bezogenen Sensings bezieht sich auf die Person als Sensing-Objekt (z.B. Sensing von körperlicher Aktivität (Mukhopadhyay, 2015), Sensing der Stimmung (z.B. Messner et al., 2019)). Umwelt-bezogenes Sensing bezieht sich hingegen z.B. auf den Zustand öffentlicher Infrastruktur, wie Straßen und Brücken, oder die Messung der Luftqualität (Dutta, Chowdhury, Roy, Middya & Gazi, 2017; Sony, Laventure & Sadhu, 2019). Aus psychologischer Sicht interessant erscheint die Weiterentwicklung von derzeit noch kaum realisierten Person-Umwelt-Sensing Möglichkeiten. Diese könnten dabei helfen, das komplexe Zusammenspiel zwischen Menschen und Umwelt differenziert zu analysieren und zu verstehen (z.B. Gesundheitsauswirkung körperlicher Aktivität in Abhängig-




Abbildung 2. Einordnung der Begrifflichkeiten innerhalb des Smart Sensings.

keit der Luftqualität; siehe beispielsweise Reichert et al. (2020) für Anwendungsbeispiele, wie sich das Leben in der Stadt auf die psychische Gesundheit auswirken kann).

Im Vergleich zu opportunistischem Sensing differenziert interaktives Sensing insbesondere den Grad der Kontrolle, die Nutzende über die erfassten Daten haben. In Bezug auf den Gegenstandsbereich der Digitalen Phänotypisierung steht insbesondere das opportunistische Sensing als Ansatz im Fokus, welches die passive Erfassung von digital abbildbaren menschlichem Verhalten als Sensing-Grundlage nutzt, wie z. B. das passive Erfassen unseres täglichen Smartphone-Nutzungsverhaltens (Montag et al., 2019), und im Gegensatz zum Ambulatory Assessment nicht rein theorie- oder hypothesengeleitet ist (Fahrenberg, 1996), sondern explorativ genutzt werden kann.

Persönliches, soziales und öffentliches Sensing bezieht sich abschließend auf die Nutzungsart der Daten, bezogen auf das Individuum (z. B. körperliches Aktivitätstracking), einer Gruppe von Menschen (z. B. Vorlieben-Sensing einer Personengruppe zur Bestimmung der gemeinsamen Schnittmenge) oder der Öffentlichkeit (z. B. Crowd-sensing (Pryss, 2019) zur Vorhersage des Straßenverkehrs).

Mit 72 % aller wissenschaftlich beschriebenen Anwendungsfällen stellt das Smartphone derzeit die zentrale Datenquelle dar (Laport-López et al., 2020). Aber auch das Auto, das Fahrrad, tragbare Geräte (Wearables) und Roboter sind vielfach untersuchte Quellen für Sensing (Laport-López et al., 2020). In Zukunft werden diese sicherlich durch weitere digitalisierte Bereiche unseres Lebens, wie zum Beispiel Smart Homes (Liu, Stroulia, Nikolaidis, Miguel-Cruz & Rios Rincon, 2016), Smart Cities (Dutta et al., 2017) und Biosensing (Dagum, 2019) grundlegend erweitert. In letzterem Kontext ist auch der Begriff des digitalen Biomarkers relevant, in der es darum geht

von digitalen Fußabdrücken beispielsweise Einblicke in die Neurobiologie einer Person zu bekommen (Montag, Elhai & Dagum, 2021a; für eine Übersicht über Forschungsbefunde siehe Montag, Elhai & Dagum, 2021b). Eine Zusammenfassung der dargestellten Konzepte und Begriffe findet sich in Abbildung 2.

KI-Grundlagen der Digitalen Phänotypisierung

Nachdem die Daten gesammelt wurden, geht es darum diese zu analysieren (Martinez-Martin et al., 2018). Dabei ist die Herausforderung, wie aus der großen Datenmenge Wissen generiert und Schlussfolgerungen gezogen werden können. In der Psychologie wird häufig hypothesengeleitet gearbeitet, das heißt, Forschende haben das Ziel, mittels einer Hypothese oder Theorie die gesammelten Daten bestmöglich zu erklären beziehungsweise die zugrundeliegenden, wahren Parameter zu schätzen. Vergangenes Verhalten wird also erklärt; dabei kann aber künftiges Verhalten mit demselben Modell nicht ebenso genau vorhergesagt werden (Yarkoni & Westfall, 2017). Beim Forschungsfeld der Digitalen Phänotypisierung hingegen haben sich die Nutzung von Data Mining-Techniken (Techniken zur Wissensgewinnung aus Datenbanken) und die Anwendung von Techniken aus dem Bereich des Machine Learning etabliert.

Diese werden im Weiteren als KI-Grundlage für Digitale Phänotypisierung beschrieben, auch wenn selbstverständlich die etablierten psychologischen Datenanalyseverfahren parallel ihre zielführende Anwendung finden.

Big Data

Der Begriff „Big Data“ kam in den frühen 2000er Jahren auf (Laney, 2001). Big Data sieht als Grundlage der Digitalen Phänotypisierung eine möglichst umfassende, granulare Matrix unserer digitalen Spuren vor, die aus einer Vielzahl von kontinuierlich erfassten Variablen von möglichst vielen Menschen besteht.

Während der Begriff *Big Data* unzureichend definiert ist (Timmons et al., 2017; Yarkoni, 2014), findet sich häufig ein Bezug auf die drei V's: Datengenerierungsgeschwindigkeit (velocity), Datenvielfalt (variety) und Datenvolumen (volume) (Laney, 2001; Ward & Barker, 2013). Dabei ist jedoch weiterhin nicht spezifiziert, ab wann Daten „big“ sind und ob es tatsächlich primär um die Datenmenge geht oder eher um die Komplexität und Variabilität. Beispielsweise ist unklar, ob auch verhältnismäßig kleine Datensätze „big“ sein könnten oder extrem große Datensätze aufgrund ihrer einfachen Datenstruktur nicht „big“ sind (Ward & Barker, 2013).

Über die genannten drei „V's“ hinaus findet sich ein viertes V zur Datengültigkeit (veracity), welches sich explizit auf die Glaubwürdigkeit bzw. Unsicherheit der Daten, sowie deren Analysen bezieht (Ward & Barker, 2013). Sind die Datenbanken erst einmal aufgebaut, werden wir mit einem großen Satz komplexer Daten konfrontiert, für die etablierte statistische Methoden teils nicht die beste Lösung sind (Baumeister & Montag, 2019). Entsprechend eng verbunden mit dem Begriff Big Data sind etablierte Datenanalyseansätze, wie das Machine und Deep Learning, die versprechen, aus dem großen Datenchaos künstlich-intelligent einen Sinn zu generieren (Lane & Georgiev, 2015; Rowe, 2019). Die Verfahren des Data Mining, Machine und Deep Learning sollen im Weiteren skizziert werden, wobei bereits an dieser Stelle auf die Komplexität und Herausforderungen im Detail hingewiesen sei (Onnela, 2021), die einen eigenständigen Beitrag erfordern würden.

Data Mining, Machine und Deep Learning

Data Mining beschreibt den Prozess des Extrahierens (mining) von Wissen aus großen Datenmengen (Big Data) (Fayyad, Piatetsky-Shapiro & Smyth, 1996). In der Literatur wird es teils auch als Wissenserkennung aus Daten (Knowledge Discovery from Data (KDD)) bezeichnet (Fayyad et al., 1996). Dieser Prozess ist nicht neu, jedoch fehlte es älteren Systemen an der notwendigen Intelligenz zu lernen, d.h. aus der vorhandenen Datenlage die bestmöglichen Schlüsse bzw. Wahrscheinlichkeitsschätzungen zu treffen und neue Informationen gewinnbringend in den Lösungsprozess zu integrieren (Rowe, 2019). Klas-

sische statistische Ansätze, wie die deskriptive oder inferentielle Statistik, erfassen einen Datensatz nur oberflächlich, können aber bei Big Data-Datensätzen nicht deren volles Potential ausschöpfen (Sariyska & Montag, 2019). Data Mining im Zusammenhang mit Smart Sensing wird in der Regel durch Algorithmen des Machine Learning durchgeführt, einschließlich des Bereichs des Deep Learning (Lima, Souto, El-Khatib, Jalali & Gama, 2019; Su, Tong & Ji, 2014). Machine Learning stellt die Gruppe an Analyseverfahren dar, die in den vergangenen Jahren zentral für die Entwicklung derartig intelligenter Systeme waren. Machine Learning beschreibt dabei die Fähigkeit eines Algorithmus zu lernen, d.h., durch die Betrachtung großer Datensätze Zusammenhänge zu erkennen und diese Erkenntnisse zur Vorhersage in neuen Datensätzen zu nutzen (Mohr et al., 2017). Unterteilen lassen sich Machine Learning-Techniken nach ihrem zugrundeliegenden Lernstil (insbesondere überwachtes, nichtüberwachtes, teilüberwachtes und bestärkendes Lernen (Das & Behera, 2017)). Zusätzlich kann dabei auch die methodische Basis des Machine Learning-Algorithmus innerhalb der Lernansätze variieren (z.B. Regression-, Bayesian-, Entscheidungsbaum-, Support Vector Machine (SVM)-, Künstliche Neuronale Netzwerk-Algorithmen (Das & Behera, 2017)).

Beim Deep Learning wiederum handelt es sich um keinen vom Machine Learning losgelösten Ansatz, sondern vielmehr um ein großskaliertes, die Generalisierbarkeit der Mustererkennung verbesserndes Analyseverfahren (Mitto, Wang, Wang, Jiang & Dudley, 2017). Durch die Anwendung von Deep Learning-Ansätzen auf große Datensätze lassen sich beispielsweise erstaunlich genaue Vorhersagen erzielen, die mit denen von Menschen vergleichbar sind (z.B. Ronao & Cho (2016)).

Da der vorliegende psychoinformatische Übersichtsbeitrag keine ausreichend spezifischen Details dieser Analyseverfahren darstellen kann, wird für interessierte Lesende auf Dey (2016) verwiesen. Zudem wird auf Walls und Schafer (2006) verwiesen, die eine Übersicht für die Anwendung statistischer Modelle auf EMA-Daten bieten. Die hier beschriebenen KI-Grundlagen von digitaler Phänotypisierung werden in Abbildung 3 vereinfacht dargestellt. Zusammenfassend lässt sich sagen, dass Data Mining-Techniken Muster in großen Datensätzen erkennen können und damit bisher unbeobachtete Daten vorhersagen können (Mohr et al., 2017; Yarkoni & Westfall, 2017). Dies stellt einen klaren Vorteil im Vergleich zu klassischen statistischen Modellen dar, bei denen es sonst schnell zu einem „Overfitting“ des Modells kommen kann (Yarkoni & Westfall, 2017). An dieser Stelle ist zu betonen, dass wir Data Mining-Techniken zwar als essentiell für den Bereich der Digitalen Phänotypisierung betrachten, jedoch bei weitem nicht für alle Forschungsfragen in der

Psychologie als geeignet ansehen. Gut konzipierte, experimentelle bzw. randomisiert kontrollierte Studien bleiben der Goldstandard um kausale Schlussfolgerungen ziehen zu können (Yarkoni & Westfall, 2017). Eine Herausforderung bleibt es Maschinelles Lernen mit theoriegeleiteter psychologischer Forschung zusammenzuführen (Elhai & Montag, 2020).




Abbildung 3. KI-basierte Grundlagen.

Unterstützende Technologien

Die Kombination aus Big Data und Machine Learning hat sich in der Vergangenheit bereits in unzähligen Bereichen bewährt. Interessanterweise haben sich in den vergangenen Jahren auch Technologien entwickelt, welche für diese Verfahren essentiell sind, bisher jedoch wenig wahrgenommen werden. Das Map-Reduce-Verfahren (Dean & Ghemawat, 2010) ist beispielsweise eine solche unterstützende Technologie. Datenstromorientierung, Graph-Datenbanken (bzw. graph-orientierte Schnittstellen) oder auch Föderiertes Lernen sind weitere Aspekte, die genannt werden können, um im Kontext der Digitalen Phänotypisierung gewinnbringend eingesetzt zu werden.

Ausgewählte empirische Befunde

Emotionen, Kognitionen und Verhalten bringen wir täglich über vielfältige Kanäle zum Ausdruck, die mittels Smart Sensing-Ansätzen erfasst, digitalisiert und ausgewertet werden können. Damit können Zusammenhänge erkannt und Anwendungen entwickelt werden, die zum Beispiel bei der Behandlung von Patientinnen und Patienten unterstützen (Insel, 2017), bei der Personalaus-

wahl helfen (Kern, McCarthy, Chakrabarty & Rizoio, 2019) oder die Platzierung zielgerichteter Produkte, abgestimmt auf die emotionale Lage von Verbraucherinnen und Verbraucher, ermöglichen (Poole, 2018). Folglich sind die Anwendungsfelder der Digitalen Phänotypisierung vielfältig, wobei die meisten empirischen Befunde bislang aus den Bereichen der Klinischen- und Gesundheitspsychologie, sowie der Differentiellen Psychologie (Vorhersage von Persönlichkeitseigenschaften; Marengo & Montag, 2020) kommen, so dass auf diese Bereiche im Folgenden beispielhaft eingegangen wird. Dabei liegt der Fokus der Ergebnisdarstellung weniger auf der Vollständigkeit, als auf der Verdeutlichung bestehender Möglichkeiten und Herausforderungen. Insgesamt sei vorweggenommen, dass sich das Forschungsfeld erst etabliert und die meisten empirischen Studien nicht über proof-of-concept Studien hinauskommen (Mohr et al., 2017).

Persönlichkeit

Eine der ersten Publikationen, die demonstrierte, dass Personenmerkmale aus digitalen Fingerabdrücken ableitbar sind, analysierte Facebook-Likes von 58.000 Teilnehmenden (Kosinski, Stillwell & Graepel, 2013). Die Autoren zeigten u. a., dass allein basierend auf den Like-Mustern der Teilnehmenden die sexuelle Orientierung (88 % Vorhersagegenauigkeit bzgl. hetero- und homosexuellen Männern), die Ethnizität (95 % bzgl. afroamerikanischer und kaukasisch-amerikanischer Ethnizität), die politische Orientierung (85 % bzgl. Demokraten vs. Republikaner) oder auch Persönlichkeitsmerkmale (wie Offenheit, $r = .43$) mit hoher prädiktiver Validität vorher-sagbar waren (Kosinski et al., 2013).

Im Bereich der Social-Media-Plattformen werden viele andere digitale Fingerabdrücke neben „Likes“, wie Status-Updates, Bilder und Analysen von geposteten Kommentaren verwendet, um Einblicke in die Eigenschaften und das wahrscheinliche zukünftige Verhalten von Personen zu erhalten (Azucar, Marengo & Settanni, 2018; Brown et al., 2019; Marengo & Montag, 2020). Ferwerda und Tkalcic (2018) untersuchten zum Beispiel die Vorhersagegültigkeit von Persönlichkeitseigenschaften basierend auf 54.962 Bildern (visuelle und inhaltliche Merkmale) von 193 Instagram-Nutzenden. Offenheit, Gewissenhaftigkeit, Extraversion, Verträglichkeit und Neurotizismus waren mit Root-mean-square error (RMSE) zwischen 0.60 und 0.99 für beide Bildanalyseeinheiten (visuell / Inhalt), ohne dass die Kombination der beiden Bildparameter eine inkrementelle prädiktive Validität ergab (Ferwerda & Tkalcic, 2018). In diesem Zusammenhang ist auch die neue Arbeit von Marengo, Settanni & Montag (2022) interessant, die Zusammenhänge zwischen extrahierten Emotions-

ausdrücken von Social-Media-Bildern und Persönlichkeitseigenschaften herstellen konnte.

Hinds & Joinson (2018) untersuchten, ob demografische Variablen von Personen anhand derer Online-Aktivität vorhergesagt werden können. Ihre systematische Übersichtsarbeit umfasste 327 Studien, die 14 demografische Merkmale untersuchten, darunter z.B. Geschlecht, Alter, Wohnort, politische und sexuelle Orientierung sowie Beruf. Ein wesentlicher Faktor zur Vorhersage solcher Merkmale sei dabei die Art der digitalen Spur. So kann beispielsweise der Sprachgebrauch (in Bezug auf Stil, Inhalt, Slang usw.) das Geschlecht und Alter vorhersagen (Hinds & Joinson, 2018).

Im Kontext der Smartphone-Sensing Analyse zeigten weitere Studien, dass Anrufvariablen mit Extraversion verbunden sind (Montag et al., 2019; Stachl et al., 2017). Darüber hinaus wurde eine längere Nutzung von WhatsApp mit einer geringeren Gewissenhaftigkeit in Verbindung gebracht (Montag et al., 2015). De Montjoye, Quoidbach, Robic & Pentland (2013) haben einen Zusammenhang zwischen Smartphone-Nutzungsverhalten (durch die Aufzeichnung von Anrufen und Nachrichten) und selbstberichteter Persönlichkeit (gemessen mit dem Big Five Inventory, BFI-44) gefunden. Mittels einer Klassifizierungsmethode (SVM als Basis des Machine Learning Algorithmus) konnten sie mit einer Genauigkeit zwischen 49 und 63% die Persönlichkeit von 69 Erwachsenen (eingeteilt in hohe, durchschnittliche und niedrige Werte von Neurotizismus, Extraversion, Gewissenhaftigkeit, Verträglichkeit und Offenheit) vorhersagen (De Montjoye et al., 2013). Mittlerweile gibt es eine Vielzahl ähnlicher Studien, die verschiedenste Sensing-Quellen mit Persönlichkeitseigenschaften assoziierten. Einen Überblick bieten Sariyska und Montag (2019), die nach Darstellung einer Vielzahl an eindrücklichen Einzelbefunden, insbesondere auch darauf hinweisen, dass es in einem nächsten Schritt um die Überprüfung komplexer Sensing-Modelle jenseits von korrelativen Einzelbefunden zwischen zwei Variablen gehen sollte, um derart den Informationswert digitaler Spuren weiter zu optimieren.

Herausforderungen und denkbare Anwendungsszenarien in der Zukunft sind zum Beispiel:

- **Soziokulturelle und demografische Diversität:** Marengo und Montag (2020) untersuchten in einer Meta-Analyse mit 21 eingeschlossenen Studien die Vorhersage der Persönlichkeit aus Facebook-Daten. Dabei verbesserte die Hinzunahme von demografischen Variablen (wie Alter, Geschlecht) die Genauigkeit der Persönlichkeitsvorhersage. Jedoch bestanden die meisten Studien aus englischsprachigen Stichproben (Marengo & Montag, 2020) oder weiblichen Teilnehmenden (Marengo, Longobardi, Fabris & Settanni, 2018), weshalb es hier zu einer Verzerrung der Ergebnisse kommen kann. In der

Arbeit um Wang & Kosinski (2018), in welcher die Autoren berichten, von Gesichtern die sexuelle Orientierung einer Person vorhergesagt zu haben, zeigt eindrücklich die ethischen Probleme, die in diesem Forschungsfeld entstehen können. Gleiches gilt für eine Folgearbeit, in der es um die Vorhersage der politischen Orientierung durch Fotos von Personen ging (Kosinski, 2021). In der Zukunft benötigt es deshalb Stichproben mit mehr soziokultureller und demografischer Vielfalt (Marengo & Montag, 2020).

- **Einbezug von neuen Datenquellen:** In den letzten Jahren haben visuelle Inhalte (bspw. das Teilen von Bildern und Videos) auf Social-Media-Plattformen stark an Bedeutung gewonnen (Marengo et al., 2018). Künftige Studien sollten Bild- und Videoinformationen zur Vorhersage der Persönlichkeitseigenschaften als Variablen in Prädiktionsmodellen aufnehmen (Marengo & Montag, 2020).
- **Monitoring und Feedback:** Übermäßige Smartphone- und Internetnutzung kann einen negativen Einfluss auf die psychische Gesundheit haben (Choi, Lee & Ha, 2012; Vaid & Harari, 2019; siehe für eine Taxonomie der Internetnutzungsstörungen die Arbeit von Montag, Wegmann, Sariyska, Demetrovics & Brand, 2021). Künstlich-intelligente Systeme könnten das Smartphone-Nutzungsverhalten oder auch die Nutzung sozialer Medien überwachen und eine Rückmeldung an die Nutzenden geben, wenn es zu einer übermäßigen Nutzung kommt. Denkbar ist, dass Nutzende bei übermäßiger Nutzung gewarnt werden und aufgefordert werden, ihren Konsum zu reduzieren (Montag, Reuter & Markowetz, 2017). So ist es beispielsweise bereits möglich, das Smartphone in bestimmten Umgebungen nicht nutzen zu können (z.B. durch das Sperren des Bildschirms; Choi et al., 2012; Vaid & Harari, 2019). Damit können Personen einen bewussten Umgang mit Medien entwickeln und eine übermäßige Nutzung zum Schutz der Gesundheit künstlich-intelligent verhindert werden.

Psychopathologie

Digitale Phänotypisierung im Kontext psychischer Störungen verfolgt zentral das Ziel, psychische Störungen, wie z.B. Depression (Wahle, Kowatsch, Fleisch, Rufer & Weidt, 2016), bipolare Störung (Ebner-Priemer et al., 2020) oder Schizophrenie (Fraccaro et al., 2019; Rough et al., 2021) durch die digitalen Spuren eines Menschen vorherzusagen sowie deren Krankheits- oder auch Behandlungsverlauf zu überwachen (Majumder & Deen, 2019). Zudem sollen Verhaltensmuster, wie Schlaf oder körperliche Aktivität, die eng mit psychischen Störungen zusammenhängen, vorhergesagt werden (Majumder & Deen, 2019).

So sammelten beispielsweise Saeb et al. (2015) zwei Wochen lang GPS-Sensordaten und Daten zum Telefonnutzungsverhalten von 28 Erwachsenen, mit dem Ziel Verhaltensmuster zu erkennen, die für den Schweregrad depressiver Symptome relevant sind. Sie identifizierten verschiedene Verhaltensmuster, wie z.B. die Mobilität zwischen Lieblingsorten ($r = .58$, $P = .012$), einen regelmäßigen 24-Stunden-Rhythmus ($r = -.63$, $P = .005$) und das Telefonnutzungsverhalten (d.h. Dauer und Häufigkeit der Nutzung: $r = .54$, $P = .011$ bzw. $r = .52$, $P = .015$), die es den Forschenden ermöglichte, mit einer Genauigkeit von 86,5 % zwischen Personen mit depressiven Symptomen und solchen ohne zu unterscheiden (Saeb et al., 2015).

Faccaro et al. (2019) fassen die Evidenz zum Vorhersagepotential schwerer psychischer Störungen (hier bipolare Störungen und Schizophrenie) mittels GPS zusammen. Während die Ergebnisse für bestehende Zusammenhänge zwischen GPS-Mustern und verschiedenen psychopathologischen Outcomes sprechen, ist die Kernschlussfolgerung der Übersichtsarbeit, dass die kleinen Fallzahlen der eingeschlossenen Primärstudien derzeit noch keine Erkenntnisse jenseits der prinzipiellen Machbarkeit erlauben.

Eine methodisch belastbarere Studie im Kontext der GPS-Nutzung zur Vorhersage sozialer Angst erfasste bei 228 Studierenden über zwei Wochen Smartphone-basierte GPS-Daten (Boukhechba, Chow, Fua, Teachman & Barnes, 2018). Es zeigte sich, dass anhand ihrer Standortmuster (z.B. Vermeidung öffentlicher Plätze, Freizeitaktivitätsradius, Zeit zu Hause) mit einer Genauigkeit von 85 % zwischen Personen mit hoher vs. niedriger sozialer Angst unterschieden werden kann (Boukhechba et al., 2018).

In Bezug auf Depression als bislang am häufigsten untersuchte Psychopathologie besteht eine Vielzahl an Digitaler Phänotypisierungsbefunden unter Nutzung verschiedenster Datenquellen, wie zum Beispiel Text, Bild und Verhaltensanalysen in sozialen Medien (z.B. Eichstaedt et al., 2018; Hussain et al., 2019; Seabrook, Kern, Fulcher & Rickard, 2018), Smartphone-basiertem Sensing (Messner et al., 2019; Moshe et al., 2021; Rozgonjuk, Elhai & Hall, 2019) bis hin zur Assoziation zwischen (Computer-)Tastaturnutzungsmustern und Depressivität (Hussain et al., 2019; Zulueta et al., 2018). So untersuchten Seabrook et al. (2018) an 29 Facebook- und 49 Twitter-Nutzenden die Vorhersagekraft emotionsidentifizierender (positiver und negativer) Wörter für depressive Stimmung. Die gegenläufigen Befunde auf Facebook und Twitter könnten für eine plattformspezifische Wortnutzung sprechen oder für eine noch fragliche Replizierbarkeit der Ergebnisse eines jungen Forschungsfeldes stehen. Eine thematisch verwandte Studie untersuchte die Vorhersagekraft von Bild,

Text und Verhaltensdaten von 512 Instagram-Nutzenden zur Vorhersage von Depression (Huang, Chiang & Chen, 2019). Die auf Machine Learning-basierenden Analysen führten zu einer sehr guten Vorhersagekraft. Interessanter als die Ergebnisse erscheint jedoch der Vergleich der beiden zuvor genannten Studien, welche einmal ausschließlich durch eine psycho-soziale Forschendengruppe (Seabrook et al., 2018) und einmal ausschließlich aus dem Informatikbereich (Huang et al., 2019) durchgeführt wurde. So schöpft die Studie von Seabrook et al. (2018) nicht das volle datenanalytische Potential aus, während Huang et al. (2019) ein komplexes Analyseverfahren unter Kombination einer Vielzahl an Dateninformationen präsentieren, basierend jedoch auf einer klinisch fraglichen Operationalisierung des Konstruktes „Depression“.

Denkbare Anwendungsszenarien in der Zukunft sind zum Beispiel:

- *Passive Diagnostik:* Das Smartphone bietet die Möglichkeit menschliches Verhalten ohne deren zutun täglich zu verfolgen. Sollten sich die über Apps, wie INSIGHTS (Montag et al., 2019), AWARE (Ferreira, Kostakos & Dey, 2015) oder RADAR (Ranjan et al., 2019), gewinnbaren Smartphone-Verhaltensdaten zur Prädiktion psychopathologischer Konstrukte, wie z.B. Depression oder Schizophrenie eignen, könnte hieraus im Hintergrund laufende Expertensysteme (Terhorst, Knauer & Baumeister, 2023) entwickelt werden, die Smartphone-Nutzende bei Anzeichen für eine klinisch bedeutsame Psychopathologie darauf hinweist und auffordert ein entsprechendes Behandlungsangebot aufzusuchen. So zeigten Narkhede et al. (2021) die prädiktive Validität aktiv (EMA) und passiv (z.B. Bewegungsdaten) erhobener Daten zur Vorhersage der negativ Symptomatik psychotischer Störungen.
- *Differentielle Indikationsstellung:* Erkenntnisse aus Behandlungsverläufen aus einer großen Anzahl an Patientinnen und Patienten, der Kombination verschiedener Sensing-Quellen, sowie aktiv erhobener Daten (Basisdokumentation, Selbstbericht, Fremdbbericht-Daten) bieten die Möglichkeit Vorhersagemodelle zum Behandlungserfolg je Behandlungsmaßnahme zu entwickeln (Terhorst et al., 2023). Derart könnte Digitale Phänotypisierung, neben der in der Medizin stark beachteten biologischen Phänotypisierung (Hamburg & Collins, 2010), zu einer personalisierten Behandlung beitragen, die individuell auf die Person abgestimmt werden kann. Hierbei scheint u.a. der Informationsgehalt verschiedener Datenquellen von Bedeutung, mit Erkenntnissen zu nur moderater Übereinstimmung zwischen klinischen Symptomeinschätzungen und mittels Digitaler Phänotypisierung vorhergesagter Negativsymptomatik bei Schizophrenie (Cohen et al., 2021; siehe auch Strauss et al., 2022).

- **Verlaufsmonitoring:** Kontinuierliches Monitoring von Behandlungsverläufen mittels (passiver) Sensing-Daten ermöglicht es Behandlungsprozesse engmaschig zu verfolgen und bei Abweichungen vom erwarteten Behandlungsverlauf Behandelnde frühzeitig aufzufordern, die aktuelle Behandlungsplanung zu überprüfen und ggf. anzupassen. Derzeit ist das Behandlungssystem in Bezug auf die Informationsgewinnung noch stark auf die jeweilige Konsultationszeit beschränkt, mit Informationslücken zwischen Behandlungssitzungen (Messner et al., 2019). Digitale Phänotypisierung bietet die Möglichkeit einer kontinuierlicheren Informationsgewinnung durch individuelle Echtzeitdaten zur Optimierung der Behandlungsplanung (Nahum-Shani et al., 2018). Gleichmaßen können derart gewonnene Daten nach Behandlungsende zur Rückfallprophylaxe herangezogen werden, um im Sinne einer Rückfallprävention frühzeitig intervenieren zu können. In diesem Kontext zeigten z.B. Barnett et al. (2018) auf, dass die Rate an Verhaltensauffälligkeiten, erhoben mittels passivem Sensing, zwei Wochen vor einem psychotischen Rückfall um 71 % höher lag, als in anderen Zeitperioden ohne folgenden Rückfall.
- **Just-in-time-adaptive Interventionen:** Als letztes Anwendungsbeispiel können digitale Informationen über eine Person (z.B. Erfassung des Stressniveaus einer Person mittels der integrierten Sensorik einer Smart-Watch (Dagum, 2019)) und über die Kontextfaktoren (z.B. Situation kurz vor Vortragspräsentation erfasst über GPS sowie der Sprache und Stimme über das Mikrofon) dazu genutzt werden, gezielte, situationsangepasste Interventionen zum richtigen Zeitpunkt anzubieten (z.B. Atemübung zur Stressreduktion) (Nahum-Shani et al., 2018; Rabbi, Klasnja, Coudhury, Tewari & Murphy, 2019; Schulte-Strathaus, Rauschenberg, Baumeister & Reininghaus, 2023).

Rahmenbedingungen für einen wissenschaftlich und ethisch fundierten Einsatz

Forschungsmethodische Standards

Die Replikationskrise psychologischer Forschungsergebnisse hat eine breite Diskussion zu notwendigen Forschungsstandards ausgelöst; Open Science Prinzipien bilden dabei die Grundlage einer transparenten und nachprüfaren Wissenschaft (Glöckner, Fiedler & Renkewitz, 2018). Der Forschungsbereich der Digitalen Phänotypisierung weist derzeit noch wenige dieser Richtlinien hoch-

wertiger, wissenschaftlicher Forschung auf (Baumeister & Montag, 2019). Wie zumeist am Anfang eines jungen Forschungsfeldes, finden sich in der Regel explorative Studien mit nur geringen Stichproben. Deren Ergebnisse sind zwar hilfreich Hypothesen zu generieren, sollten aber sicherlich nicht dafür genutzt werden, diese bereits beantworten zu wollen (Kriston, 2020). Insbesondere stellen sich folgende vier zentralen Herausforderungen, um das Potential der Digitalen Phänotypisierung auszuschöpfen und Fehlschlüsse aufgrund überinterpretierter Korrelationen zu vermeiden:

1. **Belastbare Datengrundlage:** Big Data stellt eine Voraussetzung für Digitale Phänotypisierung dar und ermöglicht es uns, Daten in noch ungeahntem Umfang zu sammeln und zu analysieren (Hinds & Joinson, 2018). Jedoch bedarf es mit zunehmender Datenkomplexität und Datenumfang belastbarer Datengewinnungs-, Datenaufbereitungs- und Datenanalysestrategien (Liang, Zheng & Zeng, 2019), die sichern, dass Ergebnisse im Zusammenhang mit der Fragestellung stehen. Verallgemeinerte Datenanalysemodelle verlieren dabei oft an Spezifität (Karlen, Mattiussi & Floreano, 2009). Daher sind robuste Data Mining-Techniken und fortgeschrittene Modelle des Machine und Deep Learning erforderlich.
2. **A-Priori definierte Studienprotokolle und Einverständniserklärung:** Eng im Zusammenhang mit der Datengrundlage steht die Notwendigkeit Forschungsvorhaben a-priori zu definieren und Datenaufbereitungs- und -analyseschritte transparent und nachvollziehbar zu machen, um derart Zufallsbefunde entlang des Publikationsbias positiver Ergebnisse zu reduzieren. Dies gilt umso mehr, je stärker sich das Forschungsfeld von explorativen, hypothesenbildenden Fragestellungen zu konfirmatorischen Forschungsvorhaben bewegt, deren Endstrecke potentiell digitale Anwendungen für vulnerable Personengruppen sein werden. Teil der Studienprotokolle sollten dabei a-priori Überlegungen zu bedeutsamen Effekten sein (Funder & Ozer, 2019). Dies wirkt zum einen „Nullergebnissen“ als Artefakt (zu) kleiner Stichproben, als auch signifikanten Effekten, die im Kontext eines Big Data-Ansatzes schnell zu Mustern ohne Wert werden können, entgegen. Wichtig zu beachten ist dabei aber genauso, dass die Einverständniserklärung (Informed Consent) zur Datenerfassung mittels Digitaler Phänotypisierung oftmals breit angelegt sein muss, da eben nicht immer hypothesengeleitet, zu einer bestimmten Forschungsfragestellung Daten gesammelt werden, wie es bei klassischen Studien in der Psychologie der Fall ist, sondern häufig erst einmal breit gestreute Daten erfasst werden. Datenschutzrechtliche Leitlinien müssen dabei die Sicherheit der Daten gewährleisten.

3. **Interdisziplinarität:** „when do we need the human-in-the-loop“ ist der Titel eines Medizininformatikbeitrages (Holzinger, 2016), der die Vorzeichenveränderung von der Unterstützung des Menschen durch Maschinen hin zu technischen Lücken, die durch Menschen sinnvoll geschlossen werden könnten, andeutet. Innerhalb von Machine Learning bieten sich interaktive Algorithmen an, die mit menschlicher Expertise an Stellen interagiert, an denen die Datenbasis unzureichend ist, die menschliche Heuristik den Algorithmen nach wie vor überlegen ist oder auch sensible Bereiche, wie z. B. Suizidalitätsbewertungen betroffen sind, die nicht an Algorithmen ausgelagert werden sollten (Holzinger, 2016; Pryss et al., 2019). Aber auch innerhalb der Kategorie „Mensch“ ist eine stärkere Interdisziplinarität erforderlich, um den komplexen Prozess der Erkenntnisgewinnung von der jeweiligen fachspezifischen Theoriebildung über die zugrundeliegenden datenwissenschaftlichen Ansätze bis hin zur fundierten Einbettung der Befunde in die Praxis abzubilden. Hierbei stellt sich für die Psychologie als Fach- und Lehrbereich die Aufgabe, das bisherige psychologische Curriculum interdisziplinär zu erweitern, da stärker als bisher auch informationstechnologische, ingenieurwissenschaftliche und KI-Kompetenzen erforderlich werden. In der Zukunft werden dabei Kooperationen mit der Industrie (z. B. durch das Apple Health Kit; Apple Inc., 2022) oder Krankenkassen (z. B. Techniker Krankenkasse) an Wichtigkeit erlangen, um Zugriff auf Daten zu erhalten, wobei die daraus resultierenden Interessenskonflikte mit entsprechenden ethischen und datenschutzrechtlichen Herausforderungen einhergehen (siehe auch Montag, Sindermann & Baumeister, 2020).
4. **Theoriebildung und -prüfung:** Während Digitale Phänotypisierung basierend auf Smart Sensing, Data Mining, Machine/Deep Learning-Ansätzen einen wertvollen Beitrag zur Forschung liefert, bedarf es weiterhin der psychologischen Theoriebildung und Forschungsmethodik, um Wissen nicht nur zu schaffen, sondern auch nachhaltig weiterzuentwickeln, mit der Notwendigkeit konfirmatorischer, experimenteller Studien (siehe auch Elhai & Montag, 2020).

Ethische und datenschutzrechtliche Leitplanken

Cao, Gao & Zhou (2019) untersuchten in ihrer Studie basierend auf Daten von 18.960 Studierenden den Zusammenhang zwischen studentischer Disziplin und Ordentlichkeit (gemessen über Duschverhalten und Mahlzeiten) und der Zielstrebigkeit (gemessen als Bibliotheks- und Lehrveranstaltungsaufenthalten). Jenseits des durch-

aus interessanten Ergebnisses eines positiven Zusammenhangs, führt diese Studie (zumindest aus westlicher Forschungsethik) die mit Digitaler Phänotypisierung eng verbundenen Themen des Datenschutzes, der Privatsphäre und des möglichen Missbrauchs der Erkenntnisse vor Augen (Kargl, van der Heijden, Erb & Bösch, 2019; Dagum & Montag, 2019). Folglich müssen sich Forschende sowohl bei Digitaler Phänotypisierung als auch allgemein im Bereich des Ambulatory Assessments verstärkt mit ethischen und datenschutzrechtlichen Fragestellungen auseinandersetzen (Cornet & Holden, 2018).

Um Digitale Phänotypisierung erfolgreich umsetzen zu können, bedarf es entsprechend Maßnahmen, die Individuen davon überzeugen, dass die aufgezeichneten Daten nicht missbräuchlich verwendet werden (Beierle et al., 2020). Stattdessen sollte die Beteiligung an Digitaler Phänotypisierung auch mit unmittelbaren Vorteilen für das Individuum einhergehen, wie z. B. ein unmittelbares Feedback zu den erhobenen Daten (z. B. graphisch aufbereitetes Smartphone-Nutzungsverhalten) (Messner et al., 2019). Dabei könnte die Einführung akzeptanzfördernder Maßnahmen die Akzeptanz gegenüber Digitaler Phänotypisierung verbessern, wie es bereits für Internet- und Mobile-basierte Gesundheitsinterventionen gezeigt werden konnte (Baumeister et al., 2014, 2015, 2020; Ebert et al., 2015). Eine der größten Herausforderungen für die Akzeptanz entsprechender Anwendungen im Kontext von Mobile Sensing ist der Energie-/Batterieverbrauch (Laport-López et al., 2020), da die Sensing-Bereitschaft der Nutzenden schnell enden wird, wenn z. B. das eigene Smartphone statt Tage nur noch wenige Stunden durchhält.

Bedenkt man weiter, dass Digitale Phänotypisierung zugrundeliegenden Sensing-Daten einen sehr privaten Einblick in das Leben der Menschen ermöglichen, sind zudem klar definierte rechtliche und ethische Standards notwendig, die Menschen vor Missbrauch schützen (Kargl et al., 2019; Martinez-Martin, Greely & Cho, 2021). Insbesondere bei der Kombination von EMA mit passiven Sensordaten sind der Schutz der Privatsphäre und die Datenspeicherung wichtig, da große Mengen persönlicher Daten gesammelt werden (de Vries et al., 2021). Digitale Phänotypisierung stellt wie so häufig erst einmal nur die technische und methodische Grundlage dar. Es ist der Mensch, der aus neutralen Techniken einen gesellschaftlichen Mehrwert schafft oder diese gegen etablierte Werte und Normen missbräuchlich nutzt. Die Manipulation von Wahlen mittels Erkenntnissen aus Digitaler Phänotypisierung stellt einen solchen Problembereich dar, in dem befürchtet wird, dass politisches Mikrotargeting demokratische Prozesse untergräbt (Ward, 2018). In ähnlicher Weise könnten Erkenntnisse zur differentiellen Wirksamkeit von Behandlungsmaßnahmen nicht nur zur Perso-

nalisation einer Behandlung, sondern auch zu einer Patientinnen- und Patientenauswahl seitens Kliniken führen, bei dem nur Personen mit einer hohen Wahrscheinlichkeit für eine frühzeitige Entlassbarkeit aufgenommen werden, welches in Zeiten von Diagnosis-Related Group (DRG) Vergütungsmodellen das betriebswirtschaftliche Ergebnis einer Klinik optimieren könnte. Ähnliche Szenarien einer Personenselektion zur Optimierung wirtschaftlicher Ziele lassen sich zum Beispiel für Versicherungsgesellschaften oder Personalauswahlverfahren denken.

Die privatwirtschaftliche und interessensgeleitete Nutzung von Digitaler Phänotypisierung hat unsere Gesellschaft längst erreicht. Globale Informationstechnologiefirmen, sowie Staaten mit einem geringer ausgeprägten Verständnis bezüglich der Individualrechte von Einzelnen, setzen Analyseergebnisse zur Produktivitätssteigerung oder auch zur Erreichung politischer Ziele längst ein (Montag & Hegelich, 2020; Montag et al., 2021c; Montag, 2021). Es scheint daher von besonderer Bedeutung, dass die Forschungsleitlinien entwickelt werden, um die ethisch und gesellschaftlich dringend notwendigen Leitplanken für Digitale Phänotypisierung zu setzen (Baumeister & Montag, 2019).

Am Beispiel der künstlichen Intelligenz lässt sich erahnen, dass Großunternehmen den Produktmarkt voraussichtlich mit immer intelligenteren Systemen revolutionieren, den Komfort von Verbrauchenden erhöhen und gleichzeitig den Bedarf an menschlichen Arbeitskräften reduzieren werden. Allerdings werden diese Unternehmen wohl nicht die dringend benötigten Antworten darauf geben, wie solche Innovationen unter Berücksichtigung aller Szenarien einer potenziell schädlichen künstlichen Intelligenz (Pistono & Yampolskiy, 2016) zum Nutzen der Gesellschaft entwickelt und umgesetzt werden können (Russell, Dewey & Tegmark, 2015).

In Deutschland wird der Datenschutz über das Bundesdatenschutzgesetz (BDSG, Bundesministerium der Justiz, 2017) geregelt. Zudem bestimmt die EU-Datenschutz-Grundverordnung (EU-DSGVO, Europäisches Parlament, 2016) den Schutz der Grundrechte von Personen in Bezug auf deren persönlichen Daten. Hier zählt Deutschland zu den Ländern mit der rigidesten Umsetzung dieser Verordnung, welche wiederum assoziierte Forschung mittels Digitaler Phänotypisierung erschwert. Inzwischen gibt es mehrere Bestreben, wie die Datenerhebung mittels Digitaler Phänotypisierung in Einklang mit Datenschutz und Forschungsethik funktionieren kann. Beispielsweise hat der Rat für Sozial- und Wirtschaftsdaten (RatSWD) Empfehlungen abgegeben, wie Maßnahmen zur Sicherung der Anonymität, Privatsphäre und Datenmanagement aussehen sollen (siehe RatSWD, 2020). Des Weiteren kann „Data Commons“ genannt werden, ein Bestreben, das biomedizinische Daten (d. h. nicht nur Rohdaten, sondern

auch Metadaten, Algorithmen etc.) aus einer Vielzahl von Quellen in einer frei zugänglichen Datenbank zur Verfügung stellt (Data Commons, o. D.). Es soll Forschenden die Möglichkeiten bieten, zusammenzuarbeiten und sich bei gleichzeitiger Wahrung von Datenschutz und Privatsphäre der Daten austauschen zu können (Klenk, Payne, Shrestha & Edmunds, 2019). Für eine praktische Sicht auf die Ethik bei der Digitalen Phänotypisierung verweisen wir auf Dagum & Montag (2019).

Um das Potenzial von Smart Sensing voll auszuschöpfen, müssen wir eine gute wissenschaftliche Praxis etablieren. Hierbei bedarf es einer ethisch und datenschutzrechtlich sensiblen Forschung, die den Ansatz der derzeitigen Korrelationsforschung in den Kontext explorativer und erklärender Forschungsparadigmen stellt. Das explorative „fishing for significance“ solle hierbei der Anfang und nicht das Ende einer methodisch fundierten psychosozialen und verhaltensbezogenen Gesundheitsforschung sein (Kriston, 2020).

Ausblick

Digitale Phänotypisierung lässt sich als Teil einer größeren wissenschaftlichen Bewegung sehen, die als Psychoinformatik bezeichnet wird (Baumeister & Montag, 2019; Markowetz, Błazskiewicz, Montag, Switala & Schlaepfer, 2014; Montag et al., 2016; Yarkoni, 2012), in der die Psychologie und Informatik zusammenarbeiten. Dabei hat vor allem in den letzten Jahren das Forschungsinteresse an Digitaler Phänotypisierung stark zugenommen (Trifan et al., 2019). Die Autoren Ebner-Priemer und Santangelo (2019) werfen die Frage auf, ob es sich bei Digitaler Phänotypisierung um einen vorübergehenden „Hype“ handle oder das Potential doch langfristig überwiegt. Kritische Auseinandersetzungen finden sich auch in Birk & Samuel (2020) und Coghlan & D'Alfonso (2021). Genau wie die Autoren um Ebner-Priemer und Santangelo (2019) kommen auch wir zum Schluss, dass das Potential, das dieses neue Forschungsvorhaben mit sich bringt, sehr vielversprechend ist. Damit diese Disziplin jedoch erfolgreich sein kann, müssen sowohl die Anstrengungen der Gesellschaft und der Politik als auch der Wissenschaft derart koordiniert werden, dass die Privatsphäre des Einzelnen geschützt wird und gleichzeitig eine wissenschaftsinitiierte Erforschung erfolgen kann, die der derzeit vor allem wirtschaftlich und politisch geleiteten Entwicklung des Bereiches einen evidenz-basierten Erkenntnisgewinn entgegensetzen kann (Montag et al., 2020). Hierbei kann und sollte die Psychologie als Disziplin die Möglichkeiten zur eigenen Weiterentwicklung nutzen, um die Chancen digitalisierter psychologischer Forschung durch gezielte Nach-




Abbildung 4. Zusammenfassung der ethischen und rechtlichen Rahmenbedingungen.

wuchsförderung weiter zu verbessern. Damit stellt aus unserer Sicht Digitale Phänotypisierung einen Quantensprung in der psychologischen Forschung dar, durch den die Erkenntnis zu den Grundlagen und Prozessen menschlichen Erlebens und Handelns weiter substantiell vertieft werden wird.

Literatur

- Apple Inc. (2022). *Health Kit*. Verfügbar unter: <https://developer.apple.com/documentation/healthkit> [24.05.2022]
- Azucar, D., Marengo, D. & Settanni, M. (2018). Predicting the Big 5 personality traits from digital footprints on social media: A meta-analysis. *Personality and Individual Differences*, 124, 150–159. <https://doi.org/10.1016/j.paid.2017.12.018>
- Barnett, I., Torous, J., Staples, P., Sandoval, L., Keshavan, M. & Onnela, J. P. (2018). Relapse prediction in schizophrenia through digital phenotyping: A pilot study. *Neuropsychopharmacology*, 43, 1660–1666. <https://doi.org/10.1038/s41386-018-0030-z>
- Baumeister, H., Nowoczin, L., Lin, J., Seifferth, H., Seufert, J., Laubner, K. & Ebert, D. D. (2014). Impact of an acceptance facilitating intervention on diabetes patients' acceptance of Internet-based interventions for depression: A randomized controlled trial. *Diabetes Research and Clinical Practice*, 105(1), 30–39. <https://doi.org/10.1016/j.diabres.2014.04.031>
- Baumeister, H. & Montag, C. (Eds.). (2019). *Digital Phenotyping and Mobile Sensing*. Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-030-31620-4>
- Baumeister, H., Seifferth, H., Lin, J., Nowoczin, L., Lütting, M. & Ebert, D. (2015). Impact of an acceptance facilitating intervention on patients' acceptance of internet-based pain interventions: A randomized controlled trial. *The Clinical Journal of Pain*, 31, 528–535. <https://doi.org/10.1097/AJP.000000000000118>
- Baumeister, H., Terhorst, Y., Grässle, C., Freudenstein, M., Nübling, R. & Ebert, D. D. (2020). Impact of an acceptance facilitating intervention on psychotherapists' acceptance of blended therapy. *PLoS ONE*, 15(8), e0236995. <https://doi.org/10.1371/journal.pone.0236995>
- Beierle, F., Tran, V. T., Allemand, M., Neff, P., Schlee, W., Probst, T. et al. (2020). What data are smartphone users willing to share with researchers? Designing and evaluating a privacy model for mobile data collection apps. *Journal of Ambient Intelligence and Humanized Computing*, 11, 2277–2289. <https://doi.org/10.1007/s12652-019-01355-6>
- Benoit, J., Onyeaka, H., Keshavan, M. & Torous, J. (2020). Systematic review of digital phenotyping and machine learning in psychosis spectrum illnesses. *Harvard Review of Psychiatry*, 28, 296–304. <https://doi.org/10.1097/HRP.0000000000000268>
- Birk, R. H. & Samuel, G. (2020). Can digital data diagnose mental health problems? A sociological exploration of 'digital phenotyping'. *Sociology of Health & Illness*, 42, 1873–1887. <https://doi.org/10.1111/1467-9566.13175>
- Boukhechba, M., Chow, P., Fua, K., Teachman, B. A. & Barnes, L. E. (2018). Predicting social anxiety from global positioning system traces of college students: Feasibility study. *Journal of Medical Internet Research*, 5(3), e10101. <https://doi.org/10.2196/10101>
- Brown, R. C., Bendig, E., Fischer, T., Goldwisch, A. D., Baumeister, H. & Plener, P. L. (2019). Can acute suicidality be predicted by Instagram data? Results from qualitative and quantitative language analyses. *PLoS ONE*, 14(9), e0220623. <https://doi.org/10.1371/journal.pone.0220623>
- Bundesministerium der Justiz. (2017). *Bundesdatenschutzgesetz*. Verfügbar unter: https://www.gesetze-im-internet.de/bds_g_2018/
- Cao, Y., Gao, J. & Zhou, T. (2019). Orderliness of campus lifestyle predicts academic performance: a case study in Chinese university. In: H. Baumeister & C. Montag (Eds.), *Digital phenotyping*

- and mobile sensing (pp. 125–137). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_8
- Choi, H. S., Lee, H. K. & Ha, J. C. (2012). The influence of smart-phone addiction on mental health, campus life and personal relations. Focusing on K university students. *Journal of the Korean Data and Information Science Society*, 23, 1005–1015.
- Coghlan, S. & D'Alfonso, S. (2021). Digital phenotyping: An epistemic and methodological analysis. *Philosophy & Technology*, 34, 1905–1928. <https://doi.org/10.1007/s13347-021-00492-1>
- Cohen, A. S., Schwartz, E., Le, T. P., Cowan, T., Kirkpatrick, B., Raugh, I. M. & Strauss, G. P. (2021). Digital phenotyping of negative symptoms: The relationship to clinician ratings. *Schizophrenia Bulletin*, 47(1), 44–53. <https://doi.org/10.1093/schbul/sbaa065>
- Cornet, V. P. & Holden, R. J. (2018). Systematic review of smart-phone-based passive sensing for health and wellbeing. *Journal of Biomedical Informatics*, 77, 120–132. <https://doi.org/10.1016/j.jbi.2017.12.008>
- Csikszentmihalyi, M. & Larson, R. (2014). Validity and reliability of the experience-sampling method. In M. Csikszentmihalyi (Ed.), *Flow and the Foundations of Positive Psychology* (pp. 35–54). Dordrecht, Springer.
- Dagum, P. (2019). Digital brain biomarkers of human cognition and mood In H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 93–107). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_6
- Dagum, P. & Montag, C. (2019). Ethical considerations of digital phenotyping from the perspective of a healthcare practitioner. In H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 13–28). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_2
- Das, K. & Behera, R. N. (2017). A survey on machine learning: Concept, algorithms and applications. *International Journal of Innovative Research in Computer and Communication Engineering*, 5, 1301–1309. <https://doi.org/10.15680/IJIRCC.2017>
- Data Commons. (o.D.). Verfügbar unter: <https://www.datacommons.org>
- Dean, J. & Ghemawat, S. (2010). MapReduce: A flexible data processing tool. *Communications of the ACM*, 53(1), 72–77. <http://doi.acm.org/10.1145/1629175.1629198>
- De Montjoye, Y. A., Quoidbach, J., Robic, F. & Pentland, A. (2013). Predicting personality using novel mobile phone-based metrics. In A. M. Greenberg, W. G. Kennedy & N. D. Bos (Eds.), *Social computing, behavioral-cultural modeling, and prediction*. SBP 2013. Lecture Notes in Computer Science, 7812 (pp. 48–55). Berlin: Springer. https://doi.org/10.1007/978-3-642-37210-0_6
- De Vries, L. P., Baselmans, B. M. L. & Bartels, M. (2021). Smart-phone-based ecological momentary assessment of well-being: A systematic review and recommendations for future studies. *Journal of Happiness Studies*, 22, 2361–2408. <https://doi.org/10.1007/s10902-020-00324-7>
- Dey, A. (2016). Machine learning algorithms: A review. *International Journal of Computer Science and Information Technologies*, 7, 1174–1179.
- Dutta, J., Chowdhury, C., Roy, S., Middya, A. I. & Gazi, F. (2017). Towards smart city: Sensing air quality in city based on opportunistic crowd-sensing. ACM International Conference Proceeding Series. <https://doi.org/10.1145/3007748.3018286>
- Ebert, D. D., Berking, M., Cuijpers, P., Lehr, D., Pörtner, M. & Baumeister, H. (2015). Increasing the acceptance of internet-based mental health interventions in primary care patients with depressive symptoms. A randomized controlled trial. *Journal of Affective Disorders*, 176, 9–17. <https://doi.org/10.1016/j.jad.2015.01.056>
- Ebner-Priemer, U. W., Mühlbauer, E., Neubauer, A. B., Hill, H., Beier, F., Santangelo, P. S. et al. (2020). Digital phenotyping: Towards replicable findings with comprehensive assessments and integrative models in bipolar disorders. *International Journal of Bipolar Disorders*, 8(1), 1–9.
- Ebner-Priemer, U. & Santangelo, P. (2019). Digital phenotyping: Hype or hope? *The Lancet Psychiatry*, 7, 297–299. [https://doi.org/10.1016/S2215-0366\(19\)30380-3](https://doi.org/10.1016/S2215-0366(19)30380-3)
- Ebner-Priemer, U. W. & Trull, T. J. (2009). Ambulatory assessment: An innovative and promising approach for clinical psychology. *European Psychologist*, 14(2), 109–119. <https://doi.org/10.1027/1016-9040.14.2.109>
- Ebner-Priemer, U. W., Kubiak, T. & Pawlik, K. (2009). Introduction to the special section: Ambulatory assessment. *European Psychologist*, 14(2), 95–97. <https://doi.org/10.1027/1016-9040.14.2.95>
- Eichstaedt, J. C., Smith, R. J., Merchant, R. M., Ungar, L. H., Crutchley, P., Preoticiu-Pietro, D. et al. (2018). Facebook language predicts depression in medical records. *Proceedings of the National Academy of Sciences of the United States of America*, 115, 11203–11208. <https://doi.org/10.1073/pnas.1802331115>
- Elhai, J. D. & Montag, C. (2020). The compatibility of theoretical frameworks with machine learning analyses in psychological research. *Current Opinion in Psychology*, 36, 83–88. <https://doi.org/10.1016/j.copsyc.2020.05.002>
- Europäisches Parlament. (2016). Verordnung (EU) 2016/679 des Europäischen Parlaments und des Rates vom 27. April 2016 zum Schutz natürlicher Personen bei der Verarbeitung personenbezogener Daten, zum freien Datenverkehr und zur Aufhebung der Richtlinie 95/46/EG (Datenschutz-Grundverordnung). Verfügbar unter: <https://bit.ly/3a6WBgv> [24.05.2022]
- Fahrenberg, J. (1996). Ambulatory assessment: Issues and perspectives. In J. Fahrenberg & M. Myrtek (Eds.), *Ambulatory assessment: Computer-assisted psychological and psychophysiological methods in monitoring and field studies* (pp. 3–20). Seattle, WA: Hogrefe and Huber.
- Fahrenberg, J. (2001). Origins and developments of ambulatory monitoring and assessment. In J. Fahrenberg & M. Myrtek (Eds.), *Progress in ambulatory assessment. Computer-assisted psychological and psychophysiological methods in monitoring and field studies* (pp. 587–614). Seattle, WA: Hogrefe and Huber.
- Fahrenberg, J., Myrtek, M., Pawlik, K. & Perrez, M. (2007). Ambulatory assessment – Monitoring behavior in daily life settings: A behavioral-scientific challenge for psychology. *European Journal of Psychological Assessment*, 23, 206–213. <https://doi.org/10.1027/1015-5759.23.4.206>
- Fayyad, U., Piatetsky-Shapiro, G. & Smyth, P. (1996). From data mining to knowledge discovery in databases. *Artificial Intelligence*, 17(3), 37–54. https://doi.org/10.1007/978-3-319-18032-8_50
- Ferreira, D., Kostakos, V. & Dey, A. K. (2015). AWARE: Mobile context instrumentation framework. *Frontiers in ICT*, 2(6). <https://doi.org/10.3389/fict.2015.00006>
- Ferwerda, B. & Tkalcic, M. (2018, 8–11 July). Predicting users' personality from Instagram pictures: Using visual and/or content features? In Proceedings of the 26th conference on user modeling, adaptation and personalization (pp. 157–161). Singapore. <https://doi.org/10.1145/3209219.3209248>
- Fraccaro, P., Beukenhorst, A., Sperrin, M., Harper, S., Palmier-Claus, J., Lewis, S. et al. (2019). Digital biomarkers from geolocation data in bipolar disorder and schizophrenia: A systematic review. *Journal of the American Medical Informatics Association*, 26, 1412–1420. <https://doi.org/10.1093/jamia/ocz043>
- Funder, D. C. & Ozer, D. J. (2019). Evaluating effect size in psychological research: Sense and nonsense. *Advances in Methods and Practices in Psychological Science*, 2, 156–168. <https://doi.org/10.1177/2515245919847202>

- Garatva, P., Terhorst, Y., Messner, E., Karlen, W., Pryss, R. & Baumeister, H. (2023). Smart sensors for health research and improvement. In C. Montag & H. Baumeister (Eds.), *Digital phenotyping and mobile sensing* (2nd ed.). Berlin: Springer. https://doi.org/10.1007/978-3-030-98546-2_23
- Glöckner, A., Fiedler, S. & Renkewitz, F. (2018). Belastbare und effiziente Wissenschaft. *Psychologische Rundschau*, 69, 22–36. <https://doi.org/10.1026/0033-3042/a000384>
- Hamburg, M. A. & Collins, F. S. (2010). The path to personalized medicine. *The New England Journal of Medicine*, 363, 301–304. <https://doi.org/https://doi.org/10.1056/NEJMp1006304>
- Hinds, J. & Joinson, A. N. (2018). What demographic attributes do our digital footprints reveal? A systematic review. *PLoS ONE*, 13(11), e0207112. <https://doi.org/10.1371/journal.pone.0207112>
- Holzinger, A. (2016). Interactive machine learning for health informatics: when do we need the human-in-the-loop? *Brain Informatics*, 3(2), 119–131. <https://doi.org/10.1007/s40708-016-0042-6>
- Huang, Y. C., Chiang, C. F. & Chen, A. L. (2019). Predicting depression tendency based on image, text and behavior data from Instagram. In *Proceedings of the 8th international conference on data science, technology and applications*, DATA (pp. 32–40). <https://doi.org/10.5220/0007833600320040>
- Hussain, F., Stange, J. P., Langenecker, S. A., McInnis, M. G., Zulueta, J., Piscitello, A. et al. (2019). Passive sensing of affective and cognitive functioning in mood disorders by analyzing keystroke kinematics and speech dynamics. In: H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 161–183). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_10
- Insel, T. R. (2017). Digital phenotyping: Technology for a new science of behavior. *JAMA*, 318(13), 1215–1216. <https://doi.org/10.1001/jama.2017.11295>
- Jain, S. H., Powers, B. W., Hawkins, J. B. & Brownstein, J. S. (2015). The digital phenotype. *Nature biotechnology*, 33, 462–463.
- Kargl, F., van der Heijden, R. W., Erb, B. & Bösch, C. (2019). Privacy in mobile sensing. In: H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 3–12). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_1
- Karlen, W., Mattiussi, C. & Floreano, D. (2009). Sleep and wake classification with ECG and respiratory effort signals. *IEEE Transactions on Biomedical Circuits and Systems*, 3(2), 71–78. <https://doi.org/10.1109/TBCAS.2008.2008817>
- Kern, M. L., McCarthy, P. X., Chakrabarty, D. & Rizoiu, M. A. (2019). Social media-predicted personality traits and values can help match people to their ideal jobs. *Proceedings of the National Academy of Sciences*, 116(52), 26459–26464. <https://doi.org/10.1073/pnas.1917942116>
- Klenk, J., Payne, P. R. O., Shrestha, R. & Edmunds, M. (2019). Open science and the future of data analytics. In M. Edmunds, C. Hass & E. Holve (Eds). *Consumer informatics and digital health*, Cham: Springer. https://doi.org/10.1007/978-3-319-96906-0_18
- Kosinski, M. (2021). Facial recognition technology can expose political orientation from naturalistic facial images. *Scientific reports*, 11(1), 1–7. <https://doi.org/10.1038/s41598-020-79310-1>
- Kosinski, M., Stillwell, D. & Graepel, T. (2013). Private traits and attributes are predictable from digital records of human behavior. *Proceedings of the National Academy of Sciences*, 110, 5802–5805. <https://doi.org/10.1073/pnas.1218772110>
- Kriston, L. (2020). Machine learning's feet of clay. *Journal of Evaluation in Clinical Practice*, 26, 373–375. <https://doi.org/10.1111/jep.13191>
- Lane, N. D. & Georgiev, P. (2015, February 12–13). Can deep learning revolutionize mobile sensing? In *Proceedings of the 16th International Workshop on Mobile Computing Systems and Applications – HotMobile '15* (pp. 117–122), Santa Fe, NM, USA. <https://doi.org/10.1145/2699343.2699349>
- Laney, D. (2001). 3D data management: Controlling data volume, velocity and variety. *META group research note*, 6(70).
- Laport-López, F., Serrano, E., Bajo, J. & Campbell, A. T. (2020). A review of mobile sensing systems, applications, and opportunities. *Knowledge and Information Systems*, 62, 145–174. <https://doi.org/10.1007/s10115-019-01346-1>
- Liang, Y., Zheng, X. & Zeng, D. D. (2019). A survey on big data-driven digital phenotyping of mental health. *Information Fusion*, 52, 290–307. <https://doi.org/10.1016/j.inffus.2019.04.001>
- Lima, W. S., Souto, E., El-Khatib, K., Jalali, R. & Gama, J. (2019). Human activity recognition using inertial sensors in a smartphone: An overview. *Sensors*, 19, 3213. <https://doi.org/10.3390/s19143213>
- Liu, L., Stroulia, E., Nikolaidis, I., Miguel-Cruz, A. & Rios Rincon, A. (2016). Smart homes and home health monitoring technologies for older adults: A systematic review. *International Journal of Medical Informatics*, 91, 44–59. <https://doi.org/10.1016/j.ijm.edinf.2016.04.007>
- Lydon-Staley, D. M., Barnett, I., Satterthwaite, T. D. & Bassett, D. S. (2019). Digital phenotyping for psychiatry: accommodating data and theory with network science methodologies. *Current Opinion in Biomedical Engineering*, 9, 8–13. <https://doi.org/10.1016/j.cobme.2018.12.003>
- Majumder, S. & Deen, M. J. (2019). Smartphone sensors for health monitoring and diagnosis. *Sensors*, 19, 2164. <https://doi.org/10.3390/s19092164>
- Marengo, D. & Montag, C. (2020). Digital phenotyping of big five personality via Facebook data mining: A meta-analysis. *Digital Psychology*, 1(1), 52–64. <https://doi.org/10.24989/dp.v1i1.1823>
- Marengo, D., Longobardi, C., Fabris, M.A. & Settanni, M. (2018). Highly-visual social media and internalizing symptoms in adolescence: The mediating role of body image concerns. *Computers in Human Behavior*, 82, 63–69.
- Marengo, D., Settanni, M. & Montag, C. (2022). Dataset on individual differences in self-reported personality and inferred emotional expression in profile pictures of Italian Facebook users. *Data in Brief*, 41, 107899. <https://doi.org/10.1016/j.dib.2022.107899>
- Markowetz, A., Błaskiewicz, K., Montag, C., Switala, C. & Schlaepfer, T. E. (2014). Psycho-Informatics: Big Data shaping modern psychometrics. *Medical Hypotheses*, 82, 405–411. <https://doi.org/10.1016/j.mehy.2013.11.030>
- Martinez-Martin, N., Greely, H. T. & Cho, M. K. (2021). Ethical development of digital phenotyping tools for mental health applications: Delphi study. *JMIR MHealth and UHealth*, 9(7), e27343. <https://doi.org/10.2196/27343>
- Martinez-Martin, N., Insel, T. R., Dagum, P., Greely, H. T. & Cho, M. K. (2018). Data mining for health: Staking out the ethical territory of digital phenotyping. *Npj Digital Medicine*, 1(68). <https://doi.org/10.1038/s41746-018-0075-8>
- Messner, E. M., Sariyska, R., Mayer, B., Montag, C., Kannen, C., Schwerdtfeger, A. & Baumeister, H. (2019). Insights: Future implications of passive smartphone sensing in the therapeutic context. *Verhaltenstherapie*, 29, 155–165. <https://doi.org/10.1159/000501735>
- Miller, G. (2012). The smartphone psychology manifesto. *Perspectives on Psychological Science*, 7, 221–237. <https://doi.org/10.1177/1745691612441215>
- Miotto, R., Wang, F., Wang, S., Jiang, X. & Dudley, J. T. (2017). Deep learning for healthcare: Review, opportunities and challenges. *Briefings in Bioinformatics*, 19, 1236–1246. <https://doi.org/10.1093/bib/bbx044>
- Mohr, D. C., Zhang, M. & Schueller, S. M. (2017). Personal sensing: Understanding mental health using ubiquitous sensors and ma-

- chine learning. *Annual Review of Clinical Psychology*, 13, 23–47. <https://doi.org/10.1146/annurev-clinpsy-032816-044949>
- Montag, C. (2021). *Du gehörst uns!* München: Blessing-Verlag.
- Montag, C., Baumeister, H., Kannen, C., Sariyska, R., Meßner, E.-M. & Brand, M. (2019). Concept, possibilities and pilot-testing of a new smartphone application for the social and life sciences to study human behavior including validation data from personality psychology. *J.*, 2(2), 102–115. <https://doi.org/10.3390/j2020008>
- Montag, C., Błaskiewicz, K., Sariyska, R., Lachmann, B., Andone, I., Trendafilov, B. et al. (2015). Smartphone usage in the 21st century: Who is active on WhatsApp? *BMC Research Notes*, 8(331). <https://doi.org/10.1186/s13104-015-1280-z>
- Montag, C., Dagum, P., Hall, B. J. & Elhai, J. D. (2021). Do we still need psychological self-report questionnaires in the age of the Internet of Things?. *Discover Psychology*, 2(1), 1–5. <https://doi.org/10.1007/s44202-021-00012-4>
- Montag, C. & Diefenbach, S. (2018). Towards homo digitalis: Important research issues for psychology and the neurosciences at the dawn of the Internet of Things and the digital society. *Sustainability*, 10(415). <https://doi.org/10.3390/su10020415>
- Montag, C., Duke, É. & Markowetz, A. (2016). Toward psychoinformatics: Computer science meets psychology. *Computational and Mathematical Methods in Medicine*, 2016, 1–10. <https://doi.org/10.1155/2016/2983685>
- Montag, C. & Elhai, J. D. (2019). A new agenda for personality psychology in the digital age? *Personality and Individual Differences*, 147, 128–134. <https://doi.org/10.1016/j.paid.2019.03.045>
- Montag, C., Elhai, J. D. & Dagum, P. (2021a). On blurry boundaries when defining digital biomarkers: How much biology needs to be in a digital biomarker? *Frontiers in Psychiatry*, 1690. <https://doi.org/10.3389/fpsy.2021.740292>
- Montag, C., Elhai, J. D. & Dagum, P. (2021b). Show me your smartphone... and then I will show you your brain structure and brain function. *Human Behavior and Emerging Technologies*, 3, 891–897. <https://doi.org/10.1002/hbe2.272>
- Montag, C. & Hegelich, S. (2020). Understanding detrimental aspects of social media use: Will the real culprits please stand up?. *Frontiers in Sociology*, 94. <https://doi.org/10.3389/fsoc.2020.599270>
- Montag, C., Hegelich, S., Sindermann, C., Rozgonjuk, D., Marengo, D. & Elhai, J. D. (2021c). On corporate responsibility when studying social media use and well-being. *Trends in Cognitive Sciences*, 25, 268–270. <https://doi.org/10.1016/j.tics.2021.01.002>
- Montag, C., Reuter, M. & Markowetz, A. (2017). The impact of psychoinformatics on internet addiction including new evidence. In C. Montag & M. Reuter (Eds.), *Internet addiction* (pp. 221–229). Cham: Springer.
- Montag, C., Sindermann, C. & Baumeister, H. (2020). Digital phenotyping in psychological and medical sciences: A reflection about necessary prerequisites to reduce harm and increase benefits. *Current Opinion in Psychology*, 36, 19–24. <https://doi.org/10.1016/j.copsyc.2020.03.013>
- Montag, C., Wegmann, E., Sariyska, R., Demetrovics, Z. & Brand, M. (2021). How to overcome taxonomical problems in the study of Internet use disorders and what to do with “smartphone addiction”? *Journal of behavioral addictions*, 9, 908–914. <https://doi.org/10.1556/2006.8.2019.59>
- Moshe, I., Terhorst, Y., Opoku Asare, K., Sander, L. B., Ferreira, D., Baumeister, H. et al. (2021). Predicting symptoms of depression and anxiety using smartphone and wearable data. *Frontiers in Psychiatry*, 12, 1–12. <https://doi.org/10.3389/fpsy.2021.625247>
- Mukhopadhyay, S. C. (2015). Wearable sensors for human activity monitoring: A review. *IEEE SENSORS JOURNAL*, 15, 1321–1330. <https://doi.org/10.1109/JSEN.2014.2370945>
- Nahum-Shani, I., Smith, S. N., Spring, B. J., Collins, L. M., Witkiewitz, K., Tewari, A. et al. (2018). Just-in-time adaptive interventions (JITIs) in mobile health: Key components and design principles for ongoing health behavior support. *Annals of Behavioral Medicine*, 52, 446–462. <https://doi.org/10.1007/s12160-016-9830-8>
- Narkhede, S. M., Luther, L., Raugh, I. M., Knippenberg, A. R., Esfahani, F. Z., Sayama, H. et al. (2021). Machine learning identifies digital phenotyping measures most relevant to negative symptoms in psychotic disorders: Implications for clinical trials. *Schizophrenia Bulletin*, sbab134. <https://doi.org/10.1093/schbul/sbab134>
- Onnela, J. P. (2021). Opportunities and challenges in the collection and analysis of digital phenotyping data. *Neuropsychopharmacology*, 46(1), 45–54. <https://doi.org/10.1038/s41386-020-0771-3>
- Pistono, F. & Yampolskiy, R. V. (2016). Unethical research: How to create a malevolent artificial intelligence. In *Proceedings of Ethics for Artificial Intelligence Workshop (AI-Ethics-2016)*. New York.
- Poole, T. (2018). Systems and methods for product placement optimization by sensing customer traffic in stores. World Intellectual Property Organization: Patent number WO2016/018897A1
- Pryss, R. (2019). Mobile crowdsensing in healthcare scenarios: Taxonomy, conceptual pillars, smart mobile crowdsensing services. In H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 221–234). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_14
- Pryss, R., Kraft, R., Baumeister, H., Winkler, J., Probst, T., Reichert, M. et al. (2019). Using chatbots to support medical and psychological treatment procedures: challenges, opportunities, technologies, reference architecture. In: H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 249–260). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_16
- Rabbi, M., Klasnja, P., Choudhury, T., Tewari, A. & Murphy, S. (2019). Optimizing mHealth interventions with a bandit. In H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 277–291). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_18
- Ranjan, Y., Rashid, Z., Stewart, C., Conde, P., Begale, M., Verbeeck, D. et al. (2019). Radar-base: Open source mobile health platform for collecting, monitoring, and analyzing data using sensors, wearables, and mobile devices. *JMIR MHealth and UHealth*, 7(8), e11734. <https://doi.org/10.2196/11734>
- Rat für Sozial- und Wirtschaftsdaten (RatSWD) (Eds.). (2020). Datenerhebung mit neuer Informationstechnologie: Empfehlungen zu Datenqualität und -management, Forschungsethik und Datenschutz, RatSWD Output, No. 6 (6), Berlin. <https://doi.org/10.17620/02671.47>
- Raugh, I. M., James, S. H., Gonzalez, C. M., Chapman, H. C., Cohen, A. S., Kirkpatrick, B. et al. (2021). Digital phenotyping adherence, feasibility, and tolerability in outpatients with schizophrenia. *Journal of Psychiatric Research*, 138, 436–443. <https://doi.org/10.1016/j.jpsychires.2021.04.022>
- Reichert, M., Braun, U., Lautenbach, S., Zipf, A., Ebner-Priemer, U., Tost, H. et al. (2020). Studying the impact of built environments on human mental health in everyday life: Methodological developments, state-of-the-art and technological frontiers. *Current Opinion in Psychology*, 32, 158–164. <https://doi.org/10.1016/j.copsyc.2019.08.026>
- Reichert, M., Gan, G., Renz, M., Braun, U., Brühlner, S., Timm, I. et al. (2021). Ambulatory assessment for precision psychiatry: Foundations, current developments and future avenues. *Experimental neurology*, 345, 113807. <https://doi.org/10.1016/j.expneurol.2021.113807>

- Robbins, M. L. & Kubiak, T. (2014). Ecological momentary assessment in behavioral medicine: Research and practice. In D. I. Mostofsky (Ed.), *The Handbook of Behavioral Medicine* (1st ed., pp. 429–446). Hoboken, NJ, USA: John Wiley & Sons, Inc. <https://doi.org/10.1002/9781118453940.ch20>
- Ronao, C. A. & Cho, S. B. (2016). Human activity recognition with smartphone sensors using deep learning neural networks. *Expert Systems with Applications*, 59, 235–244. <https://doi.org/10.1016/j.eswa.2016.04.032>
- Rowe, M. (2019). An introduction to machine learning for clinicians. *Academic Medicine*, 94, 1433–1436. <https://doi.org/10.1097/ACM.0000000000002792>
- Rozgonjuk, D., Elhai, J. D. & Hall, B. J. (2019). Studying psychopathology in relation to smartphone use. In: H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 185–199). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_11
- Russell, S., Dewey, D. & Tegmark, M. (2015). Research priorities for robust and beneficial artificial intelligence. *AI Magazine*, 36(4), 105–114. <https://doi.org/10.1609/aimag.v36i4.2577>
- Saab, S., Zhang, M., Karr, C. J., Schueller, S. M., Corden, M. E., Kording, K. P. et al. (2015). Mobile phone sensor correlates of depressive symptom severity in daily-life behavior: An exploratory study. *Journal of Medical Internet Research*, 17(7), e175. <https://doi.org/10.2196/jmir.4273>
- Sariyska, R. & Montag, C. (2019). An overview on doing psychodiagnostics in personality psychology and tracking physical activity via smartphones. In H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 45–63). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_4
- Schulte-Strathaus, J. C., Rauschenberg, C., Baumeister, H. & Reininghaus, U. (2023). Ecological momentary interventions in public mental health provision. In C. Montag & H. Baumeister (Eds.), *Digital phenotyping and mobile sensing* (2nd ed.). Berlin: Springer. https://doi.org/10.1007/978-3-030-98546-2_25
- Schwarz, N. (2008). Attitude measurement. In W. D. Crano & R. Prislin (Eds.), *Attitudes and attitude change* (pp. 41–60). New York: Psychology Press.
- Seabrook, E. M., Kern, M. L., Fulcher, B. D. & Rickard, N. S. (2018). Predicting depression from language-based emotion dynamics: Longitudinal analysis of Facebook and Twitter status updates. *Journal of Medical Internet Research*, 20(5), e168. <https://doi.org/10.2196/jmir.9267>
- Shiffman, S., Stone, A. A. & Hufford, M. R. (2008). Ecological momentary assessment. *Annual Review of Clinical Psychology*, 4, 1–32. <https://doi.org/10.1146/annurev.clinpsy.3.022806.091415>
- Sony, S., Laventure, S. & Sadhu, A. (2019). A literature review of next-generation smart sensing technology in structural health monitoring. *Structural Control and Health Monitoring*, 26(3), e2321. <https://doi.org/10.1002/stc.2321>
- Stachl, C., Hilbert, S., Au, J. Q., Buschek, D., De Luca, A., Bischl, B. et al. (2017). Personality traits predict smartphone usage. *European Journal of Personality*, 31, 701–722. <https://doi.org/10.1002/per.2113>
- Stone, A. A. & Shiffman, S. (1994). Ecological momentary assessment (EMA) in behavioral medicine. *Annals of Behavioral Medicine*, 16, 199–202. <https://doi.org/10.1093/abm/16.3.199>
- Strauss, G. P., Raugh, I. M., Zhang, L., Luther, L., Chapman, H. C., Allen, D. N. et al. (2022). Validation of accelerometry as a digital phenotyping measure of negative symptoms in schizophrenia. *Schizophrenia*, 8(1), 1–6. <https://doi.org/10.1038/s41537-022-00241-z>
- Su, X., Tong, H. & Ji, P. (2014). Activity recognition with smartphone sensors. *Tsinghua Science and Technology*, 19, 235–249. <https://doi.org/10.1109/TST.2014.6838194>
- Terhorst, Y., Knauer, J. & Baumeister, H. (in press). Smart sensing Enhanced Diagnostic Expert Systems. In C. Montag & H. Baumeister (Eds.), *Digital Phenotyping and Mobile Sensing* (2nd ed.). Berlin: Springer. https://doi.org/10.1007/978-3-030-98546-2_24
- Timmons, A. C., Baucom, B. R., Han, S. C., Perrone, L., Chaspari, T., Narayanan, S. S. et al. (2017). New frontiers in ambulatory assessment: Big data methods for capturing couples' emotions, vocalizations, and physiology in daily life. *Social Psychological and Personality Science*, 8, 552–563. <https://doi.org/10.1177/1948550617709115>
- Torous, J., Kiang, M. V., Lorme, J. & Onnela, J.-P. (2016). New tools for new research in psychiatry: A scalable and customizable platform to empower data driven smartphone research. *JMIR Mental Health*, 3(2), e16. <https://doi.org/10.2196/mental.5165>
- Trifan, A., Oliveira, M. & Oliveira, J. L. (2019). Passive sensing of health outcomes through smartphones: Systematic review of current solutions and possible limitations. *JMIR MHealth and UHealth*, 7(8), e12649. <https://doi.org/10.2196/12649>
- Trull, T. J. & Ebner-Priemer, U. (2013). Ambulatory assessment. *Annual Review of Clinical Psychology*, 9, 151–176. <https://doi.org/10.1146/annurev-clinpsy-050212-185510>
- Trull, T. J. & Ebner-Priemer, U. W. (2009). Using Experience Sampling Methods/Ecological Momentary Assessment (ESM/EMA) in clinical assessment and clinical research: Introduction to the special section. *Psychol Assess*, 21, 457–462. <https://doi.org/10.1037/a0017653>
- Vaid, S. S. & Harari, G. M. (2019). Smartphones in personal informatics: a framework for self-tracking research with mobile sensing. In H. Baumeister & C. Montag (Eds.), *Digital phenotyping and mobile sensing* (pp. 45–63). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-31620-4_4
- Van Roekel, E., Keijsers, L. & Chung, J. M. (2019). A review of current ambulatory assessment studies in adolescent samples and practical recommendations. *Journal of Research on Adolescence*, 29, 560–577. <https://doi.org/10.1111/jora.12471>
- Wahle, F., Kowatsch, T., Fleisch, E., Rufer, M. & Weidt, S. (2016). Mobile sensing and support for people with depression: A pilot trial in the wild. *JMIR MHealth and UHealth*, 4(3), e111. <https://doi.org/10.2196/mhealth.5960>
- Walls, T. A. & Schafer, J. L. (Eds.). (2006). *Models for Intensive Longitudinal data*. New York: Oxford University.
- Wang, Y. & Kosinski, M. (2018). Deep neural networks are more accurate than humans at detecting sexual orientation from facial images. *Journal of personality and social psychology*, 114, 246–257. <https://doi.org/10.1037/pspa0000098>
- Ward, K. (2018). Social networks, the 2016 US presidential election, and Kantian ethics: Applying the categorical imperative to Cambridge Analytica's behavioral microtargeting. *Journal of Media Ethics*, 33(3), 133–148. <https://doi.org/10.1080/23736992.2018.1477047>
- Ward, J. S. & Barker, A. (2013). Undefined by data: A survey of big data definitions. *ArXiv Preprint*, arXiv:1309.5821. <https://doi.org/10.48550/arXiv.1309.5821>
- Wilhelm, P., Perrez, M. & Pawlik, K. (2012). Conducting research in daily life: A historical review. In M. R. Mehl & T. S. Conner (Eds.), *Handbook of research methods for studying daily life* (pp. 62–86). New York, NY, USA: The Guilford Press.
- Yarkoni, T. (2012). Psychoinformatics: New horizons at the interface of the psychological and computing sciences. *Current Directions in Psychological Science*, 21, 391–397. <https://doi.org/10.1177/0963721412457362>

- Yarkoni, T. (2014). *Big Data, n. A kind of black magic*. Retrieved from <http://www.talyarkoni.org/blog/2014/05/19/big-data-n-a-kind-of-black-magic/> [18.05.2022]
- Yarkoni, T. & Westfall, J. (2017). Choosing prediction over explanation in psychology: Lessons from machine learning. *Perspectives on Psychological Science*, 12, 1100–1122. <https://doi.org/10.1177/1745691617693393>.
- Zulueta, J., Piscitello, A., Rasic, M., Easter, R., Babu, P., Langenecker, S. A. et al. (2018). Predicting mood disturbance severity with mobile phone keystroke metadata: A biaffect digital phenotyping study. *Journal of Medical Internet Research*, 20(7), e241. <https://doi.org/10.2196/jmir.9775>

Historie

Onlineveröffentlichung: 20. September 2022

Förderung

Open Access Veröffentlichung ermöglicht durch die Universität Ulm.

Prof. Dr. Harald Baumeister, Dipl. Psych., PP

Abteilung für Klinische Psychologie und Psychotherapie
Institut für Psychologie und Pädagogik
Universität Ulm
Lise-Meitner-Straße 16
89069 Ulm
Deutschland
harald.baumeister@uni-ulm.de