

Der gläserne Nutzer: Wie Künstliche Intelligenz aus unbewussten digitalen Verhaltensmustern tiefgreifende Rückschlüsse zieht

Einleitung: Der Paradigmenwechsel von expliziten zu impliziten Daten

Die Interaktion zwischen Mensch und Maschine hat in der jüngeren technologischen Evolution eine fundamentale Transformation erfahren. Während frühere Generationen der Datenanalyse primär auf die bewusste, explizite Eingabe von Informationen angewiesen waren – also auf Daten, die ein Nutzer aktiv in ein Suchfeld tippt, in einem Formular auswählt oder auf einer Social-Media-Plattform publiziert –, fokussieren sich moderne Architekturen der Künstlichen Intelligenz (KI) auf die sogenannten digitalen Abgase („Digital Exhaust“). Es ist im aktuellen informationstechnologischen Paradigma nicht mehr ausschlaggebend, *was* ein Individuum kommuniziert, sondern *wie, wann, in welcher Frequenz und in welchem räumlichen Kontext* diese Kommunikation stattfindet.¹

Diese analytische Methodik, die in der akademischen Literatur häufig als „Inference-based Profiling“ (IBP) oder im medizinischen Kontext als „Digital Phenotyping“ (digitale Phänotypisierung) bezeichnet wird, ermöglicht es tiefen neuronalen Netzen, komplexe Muster in scheinbar banalen, unbewusst generierten Metadaten zu identifizieren.¹ Das maschinelle Lernen quantifiziert Mikroverhaltensweisen auf einer Granularitätsstufe, die der menschlichen Wahrnehmung entgeht: von der exakten Millisekunde, in der eine Taste auf einer physischen Tastatur oder einem Smartphone-Touchscreen gehalten wird, über den Rhythmus des Wechsels zwischen Applikationen bis hin zur geodätischen Entropie des täglichen Bewegungsprofils.⁵

Das Resultat dieser algorithmischen Synthese ist eine hochauflösende, kontinuierliche und multidimensionale Abbildung der physischen, psychologischen, demografischen und sozioökonomischen Realität des Nutzers.⁷ Die vorliegende Untersuchung analysiert die Mechanismen, Reichweiten und tiefgreifenden Implikationen dieser KI-gestützten Rückschlüsse. Im Zentrum steht die Beantwortung der Frage, inwieweit algorithmische Systeme in der Lage sind, aus non-sensiblen, unbewusst generierten Eingaben – wie der individuellen Tippgeschwindigkeit, spezifischen Rechtschreibanomalien, Nutzungszeiten und geografischen Koordinaten – auf hochsensible Attribute wie neurodegenerative Krankheitsbilder, psychiatrische Störungen, den sozioökonomischen Status und fundamentale Persönlichkeitsmerkmale zu schließen.

Verhaltensbiometrie der Eingabe: Die Tastatur als kognitiver Sensor

Die physische Interaktion mit einer Hardware-Tastatur oder einem virtuellen Touchscreen ist kein rein mechanischer, sondern ein hochkomplexer neuromuskulärer und kognitiver Prozess. Die Disziplin der Tastendynamik („Keystroke Dynamics“) erfasst und analysiert Metriken, die weit über den resultierenden Textinhalt hinausgehen und eine Brücke zwischen dem zentralen Nervensystem und dem digitalen Endgerät schlagen. KI-Systeme transformieren diese Hardware in hochsensible Diagnose- und Profiling-Instrumente.⁵

Zu den primären Merkmalen der Tastendynamik gehören die „Hold Time“ (Haltedauer), also die Zeitspanne vom initialen Drücken bis zum Loslassen einer spezifischen Taste, und die „Flight Time“ (Flugzeit), welche die exakte Latenz zwischen dem Loslassen einer Taste und dem Anschlagen der darauffolgenden Taste misst.⁵ Bei der Nutzung von Touchscreen-Geräten werden diese Datenpunkte zusätzlich um Druckintensität, Wischgeschwindigkeit, den genauen Aufschlagwinkel des Fingers und die Größe der Kontaktfläche erweitert.⁵ Diese scheinbar insignifikanten, mikroskopischen Zeit- und Druckintervalle unterliegen kontinuierlichen Fluktuationen, die durch den emotionalen, kognitiven, demografischen und physischen Zustand des Nutzers auf vorhersagbare Weise moduliert werden.⁵

Erkennung von demografischen Grundparametern

Das Tippverhalten ist nicht über die Lebensspanne hinweg statisch, sondern reflektiert die altersbedingten Veränderungen in der neuromuskulären Verarbeitungsgeschwindigkeit und der kognitiven Plastizität. Umfangreiche Feldstudien demonstrieren, dass KI-Modelle in der Lage sind, das chronologische Alter und das biologische Geschlecht eines Nutzers mit bemerkenswerter Präzision zu extrahieren, ohne dass der Nutzer diese Daten jemals explizit angegeben hat.⁸

In einer groß angelegten Untersuchung an gesunden Erwachsenen, in der über 2,5 Millionen Tipp-Sitzungen mittels einer modifizierten Smartphone-Tastatur aufgezeichnet wurden, extrahierten die Forscher 43 distinkte Verhaltensmerkmale aus den Kategorien Geschwindigkeit, Frequenz und temporale Variabilität.⁹ Jüngere Kohorten zeichneten sich durch eine signifikant höhere "Flight Time"-Geschwindigkeit und spezifische fließende Tastenübergänge aus, insbesondere bei sogenannten Down-Down-Latenzen (der Zeit zwischen dem Drücken zweier aufeinanderfolgender Tasten).⁸

Durch den Einsatz fortschrittlicher Klassifikatoren wie Random-Forest-Algorithmen, Transformer-Netzwerken und Long Short-Term Memory (LSTM) Modellen konnten die Systeme die altersgruppenspezifischen Verhaltenssignaturen mit einer Genauigkeit von über 70 % vorhersagen.⁹ Erweitert man die Datenbasis um die Dynamik von Mausbewegungen an Desktop-Systemen – analysiert nach Richtungsverteilungen, Winkelvarianzen, Pfadabweichungen (dem Verhältnis des tatsächlichen Pfades zur mathematisch kürzesten Distanz) und Bewegungsgeschwindigkeiten –, steigen die F-Scores entsprechender Support Vector Machines (SVM) und neuronaler Netze für die Prädiktion von Alter und Geschlecht auf

Werte von über 0,9.¹⁴ Ein System kann somit allein durch die Beobachtung der Cursor-Navigation auf einer Website präzise demografische Profile generieren.

Emotionale Zustände, Stress und kognitive Ermüdung

Die Fluktuationen in der Tastendynamik erlauben tiefgreifende Einblicke in temporäre affektive Zustände. Untersuchungen im interdisziplinären Feld des „Affective Computing“ belegen, dass Emotionen signifikante und maschinell quantifizierbare Varianzen in der Rhythmik der Texteingabe erzeugen.¹⁰ Die psychologischen Dimensionen von Arousal (Erregungsniveau) und Valenz (Wertigkeit der Emotion) beeinflussen die motorische Ausführung der Tippbewegung direkt.¹⁰

Varianzanalysen (wie zweifaktorielle ANOVA mit Messwiederholung) zeigen, dass Valenz und Arousal einen erheblichen Anteil der Variabilität in der Tastenlatenz erklären, selbst nachdem individuelle Grundunterschiede herausgerechnet wurden.¹⁰ Unter Stress oder kognitiver Überlastung nimmt die reine Tippgeschwindigkeit nicht zwangsläufig signifikant ab, jedoch wird die Rhythmik messbar erratischer. Ein wesentlicher Indikator für kognitive Anspannung ist ein Anstieg der Nutzung der Backspace-Taste zur Fehlerkorrektur sowie eine Häufung von Autokorrektur-Ereignissen und eine Reduktion der lexikalischen Diversität im generierten Text.¹⁰ Moderne KI-Architekturen sind in der Lage, aus extrem kurzen Zeitfenstern von lediglich 30 Sekunden Tippverhalten auf den spezifischen emotionalen Zustand – wie Wut, Freude, Langeweile oder Frustration – zu schließen. Systeme, die auf Random-Forest-Klassifikatoren basieren, erreichen in kontrollierten Studien Klassifikationsgenauigkeiten von durchschnittlich 84 %.¹⁰ Ein weiteres hochrelevantes Anwendungsfeld ist die Detektion von chronischer mentaler Ermüdung („Mental Fatigue“). Durch die Domänentransformation tiefer neuronaler Netze (wie beispielsweise *TypeNet*), die ursprünglich für die reine Nutzerauthentifizierung konzipiert wurden, können Modelle trainiert werden, die Ermüdungszustände und den zirkadianen Rhythmus eines Nutzers kontinuierlich im Hintergrund überwachen.²² Diese Modelle klassifizieren Ermüdungszustände anhand der natürlichen Tippmuster mit einer Area Under the Curve (AUC) von bis zu 80 %, was eine völlig unaufdringliche, kontinuierliche Überwachung der mentalen Leistungsfähigkeit ermöglicht.²²

Metrik der Verhaltensbiometrie	Primärer kognitiver/physischer Indikator	Algorithmische Interpretation
Flight Time (Flugzeit)	Neuromotorische Verarbeitungsgeschwindigkeit	Altersschätzung, Identifikation von feinmotorischem Abbau. ⁵
Hold Time (Haltedauer)	Affektiver Zustand, muskuläre Rigidität	Stresserkennung, Erschöpfung, frühe Parkinson-Detektion. ⁵
Down-Down Digram Latency	Automatisierungsgrad der Motorik	Geschlechts- und Altersprädiktion, Identitätsverifikation. ⁸
Korrekturfrequenz	Kognitive Belastung,	Stress, Angstzustände,

(Backspace)	Unsicherheit	reduzierte Konzentrationsfähigkeit. ¹⁰
Maus-Pfadabweichung	Räumlich-visuelle Orientierung, Zögern	Demografisches Profiling, Erkennung von Social-Engineering. ¹⁴

Neurodegenerative Biomarker: Fehler-Typologien und linguistische Regression

Die ethisch brisantesten und technologisch faszinierendsten Rückschlüsse, die aus der Analyse von non-sensiblen Eingabedaten gezogen werden können, betreffen die menschliche Gesundheit. Da sowohl die motorische Ausführung des Tippens als auch die linguistische und syntaktische Konstruktion des Geschriebenen essenzielle, weit verteilte Gehirnareale beanspruchen, manifestieren sich neurodegenerative Erkrankungen wie Morbus Parkinson und die Alzheimer-Demenz in hochspezifischen digitalen Biomarkern. Diese Muster sind durch KI messbar, Jahre bevor klinisch eindeutige Symptome den Patienten zu einem Neurologen führen würden.²⁴

Morbus Parkinson: Verlust der Gewohnheitsmotorik und Rhythmusanomalien

Morbus Parkinson (PD) ist physiologisch primär durch den fortschreitenden Verlust dopaminerger Neuronen in der Substantia nigra gekennzeichnet, was die Funktion der Basalganglien – insbesondere des kaudalen Putamens – gravierend beeinträchtigt.²⁶ Da das kaudale Putamen im menschlichen Gehirn maßgeblich für die reibungslose Ausführung hochgradig automatisierter motorischer Gewohnheiten verantwortlich ist, führt seine frühe Degeneration zu einer paradoxen und maschinell extrem gut auswertbaren Veränderung im Tippverhalten.²⁶

Ein zentrales Konzept hierbei ist die Theorie der „habit-driven errors“ (Gewohnheitsfehler). Wenn gesunde Individuen schnell tippen, ruft ihr motorisches System häufig stark trainierte Tasten-Sequenzen (wie etwa die englische Endung „-ing“) automatisch ab. Dies führt zu typischen Tippfehlern, bei denen eine gewohnte Sequenz fehlerhaft in einem unpassenden Wort angewendet wird (beispielsweise das Tippen von „thing“ anstatt des intendierten „think“).²⁶ Parkinson-Patienten verlieren bereits im Frühstadium der Erkrankung zunehmend diese Fähigkeit zur Automatisierung. Um den Verlust der Habitualisierung zu kompensieren, muss ihr Gehirn auf das wesentlich langsamere, kognitiv anstrengendere und zielgerichtete Kontrollsystem der intakten assoziativen Territorien zurückgreifen.²⁶

KI-Systeme, die String-Alignment-Algorithmen wie den Needleman-Wunsch-Algorithmus verwenden, um Substitutionen, Insertionen und Deletionen in Tippprotokollen zu klassifizieren, erkennen bei Parkinson-Patienten eine statistisch signifikante *Abnahme* dieser Gewohnheitsfehler.²⁶ Gleichzeitig steigt die Rate an simplen, unkoordinierten motorischen Fehlern. Die paradoxe Erkenntnis ist demnach: Das Fehlen spezifischer, komplexer Tippfehler ist

ein starker Indikator für den Verlust der Funktion der Basalganglien.²⁶

Darüber hinaus analysieren Convolutional Neural Networks (CNNs) und Feature-Extraktions-Algorithmen (wie der FRESH-Algorithmus) die rein zeitlichen und dynamischen Aspekte der Tastenanschläge in hochdimensionalen Matrizen.⁵ Zentrale Biomarker umfassen:

1. **Mean Absolute Consecutive Difference (MACD):** Eine Metrik, welche die dynamische Variation zwischen aufeinanderfolgenden Tastenanschlägen quantifiziert und transiente Bradykinesie (mikroskopische Bewegungsverlangsamungen) detektiert, die dem menschlichen Auge völlig verborgen bleiben.⁵
2. **Räumlich-zeitliche Asymmetrie:** KI-Modelle identifizieren systematische Seitendifferenzen in den Latenzzeiten zwischen der linken und der rechten Hand, ein klassisches Frühsymptom asymmetrischer dopaminerger Degeneration.²⁹
3. **Druck- und Tremor-Indikatoren:** Die Variabilität des Fingerdrucks auf Touchscreen-Oberflächen und mikroskopische Ruckelbewegungen („Jerkiness“) werden als frühe Manifestationen des Ruhetremors klassifiziert.⁵

Modelle, die diese unbewussten Zeitreihendaten aggregieren und durch rekurrierende neuronale Netze jagen, erreichen in klinisch validierten Studien Receiver Operating Characteristic (ROC)-Werte (AUC) von bis zu 0,98. Sie differenzieren mit über 95 % Sensitivität und Spezifität zwischen Parkinson-Patienten im Frühstadium und gesunden Kontrollgruppen, allein basierend auf den Hintergrunddaten eines Standard-Keyboards.⁵ Ähnliche Genauigkeiten (über 95 %) werden bei der Analyse von Handschrift-Mustern mittels magnetischer Tinte erreicht, bei denen KI die elektrische Signalgebung von On-Surface- und In-Air-Schreibbewegungen auswertet.³¹

Alzheimer-Demenz: Phonemische Unplausibilität und semantische Erosion

Während sich Morbus Parkinson primär in den motorischen Rhythmen des Tastenanschlags offenbart, manifestiert sich die Alzheimer-Demenz (AD) in den frühen Stadien vorwiegend in der Architektur der Sprache und spezifischen orthografischen Zerfallserscheinungen. Die Künstliche Intelligenz analysiert hierbei weniger die millisekundengenaue Geschwindigkeit der Finger, sondern vielmehr die Semantik, die Syntaxstruktur und die tieferliegende Typologie der produzierten Rechtschreibfehler.³²

Ein hochspezifischer, früher Biomarker für die Alzheimer-Erkrankung ist das gehäufte Auftreten von sogenannten phonemisch unplausiblen Buchstabierfehlern („phonemically implausible spelling errors“).²⁵ Während gesunde Individuen bei Flüchtigkeitsfehlern auf der Tastatur meist typografische (benachbarte Tasten) oder phonetisch konsistente Fehler machen, produzieren AD-Patienten Fehler, die phonetisch keinen Sinn mehr ergeben (wie etwa die Eingabe von „enough“ anstatt „enough“).²⁵ Regressionsanalysen belegen, dass diese spezifischen Fehler nicht primär durch eine generelle Sprachstörung, sondern durch tiefgreifende Defizite in der visuellen Aufmerksamkeit und im graphemischen Arbeitsgedächtnis (Graphemic Buffer) bedingt sind.³⁵

Neben der reinen Orthografie nutzen KI-Systeme Natural Language Processing (NLP) und fortschrittliche Wort-Embeddings (wie FastText), um den sukzessiven Verlust der semantischen Granularität im Vokabular des Nutzers zu quantifizieren. Der Algorithmus kartografiert die Wortwahl anhand von taxonomischen Datenbanken wie WordNet.³⁴ Dabei zeigt sich, dass Alzheimer-Patienten im Frühstadium eine messbare Neigung entwickeln, präzise Hyponyme (spezifische Unterbegriffe wie „Katze“ oder „Beere“) durch abstrakte Hyperonyme (generische Überbegriffe wie „Tier“ oder „Frucht“) zu ersetzen.³⁴ Gleichzeitig detektieren die NLP-Modelle abrupte Veränderungen im Sprachfluss, thematische Diskontinuität und längere Pausen, die auf Wortfindungsschwierigkeiten (WFD - Word-Finding Difficulty) hinweisen.³⁴

Auch die syntaktische Struktur unterliegt einer durch Algorithmen erfassbaren Regression. KI-gestützte Analysen weisen nach, dass eine Reduktion der syntaktischen Komplexität, gemessen an kürzeren Abhängigkeitsdistanzen (Dependency Distance) in verschachtelten Sätzen und Schwierigkeiten bei der korrekten Integration von Klitika (unbetonten Wörtern), stark mit kognitivem Verfall korreliert.³⁸ Die historische und bahnbrechende „Nun Study“ hatte bereits vor Jahrzehnten manuell demonstriert, dass die sogenannte „Idea Density“ (ID) in den autobiografischen Texten junger Novizinnen ein hochpräziser Prädiktor für die Entwicklung von Alzheimer-Demenz bis zu sechs Jahrzehnte später ist.⁴⁰ Moderne KI-gestützte Systeme operationalisieren und skalieren diese Erkenntnis nun, indem sie die alltäglichen, unstrukturierten Texteingaben (von Suchanfragen über E-Mails bis hin zu Social-Media-Posts) kontinuierlich auf diese schleichenden linguistischen Erosionsprozesse und den Verlust der kognitiven Reserve überwachen.³⁴

Diagnose-Metrik	Profilierung Morbus Parkinson (PD)	Profilierung Alzheimer-Demenz (AD)	Algorithmische Nachweismethode
Kognitiv-Motorische Basis	Dysfunktion des kaudalen Putamens (Basalganglien)	Defizite im graphemischen Puffer & semantischen Netz	Zeitreihenanalyse vs. Natural Language Processing
Fehler-Typologie	<i>Rückgang</i> von Automatismen (Habit Slips), Anstieg einfacher motorischer Fehler. ²⁶	<i>Anstieg</i> von phonemisch unplausiblen Rechtschreibfehlern (z.B. falsche Grapheme). ²⁵	String-Alignment (Needleman-Wunsch) vs. phonetische Wörterbücher
Temporale Dynamik	Signifikante Bradykinesie, messbare Asymmetrie der Hände, Mikro-Tremor. ⁵	Latenzen primär bedingt durch Wortfindungsschwierigkeiten (WFD) während des Schreibprozesses. ³⁶	Convolutional Neural Networks (CNN) auf Haltedauer/Flugzeit
Linguistische Konstruktion	Erhöhte Nutzung von Verben, Reduktion von	Verlust semantischer Granularität	Word-Embeddings (FastText) und

	Nomen und Füllwörtern. ³⁷	(Hypernyme statt Hyponyme), syntaktische Simplifizierung. ³⁴	Taxonomie-Abgleich (WordNet)
Prädiktive Leistungsfähigkeit	Bis zu 98 % Genauigkeit (AUC 0.98) in klinischen Modellen. ²⁹	Hohe Vorhersagekraft für den Übergang von MCI (Mild Cognitive Impairment) zu AD. ³⁵	Random Forest, LSTM Autoencoder, Support Vector Machines

Digitale Phänotypisierung: Das Metadaten-Profil der mentalen Gesundheit

Während sich die verhaltensbiometrische Analyse der Tastatur auf die Mikrodynamik eines isolierten physischen Prozesses konzentriert, spannt die „Digitale Phänotypisierung“ (Digital Phenotyping) das Netz wesentlich weiter. Sie aggregiert die Makroebene des Nutzerverhaltens: Uhrzeiten, Nutzungshäufigkeiten, App-Wechsel, Bildschirmaktivitätszyklen und Sensordaten (Beschleunigungsmesser, Gyroskope), um ein tief greifendes, ökologisch valides Verständnis der psychischen und physischen Verfassung in der natürlichen Umgebung des Nutzers zu erzeugen.⁴

Dieser Ansatz hat die psychiatrische und psychologische Forschung revolutioniert. Das Smartphone fungiert hierbei als ubiquitärer, passiver Sensor, der ununterbrochen Metadaten in Echtzeit sammelt. Komplexe Machine-Learning-Algorithmen (wie eXtreme Gradient Boosting (XGBoost) und Long Short-Term Memory (LSTM) Netzwerke) sind in der Lage, aus diesen aggregierten Metadaten den Schweregrad von Depressionen, generalisierten Angststörungen, Bipolarität und Schizophrenie mit hoher Zuverlässigkeit zu prognostizieren, ohne auch nur ein einziges Wort des inhaltlichen Austauschs zu transkribieren.⁴²

Depression und Bipolare Affektive Störungen

Die Varianz, Architektur und Regelmäßigkeit des Schlafs sowie der übergeordnete zirkadiane Rhythmus sind fundamentale Indikatoren für affektive Störungen. Da die wenigsten Nutzer dedizierte Schlafracker tragen, inferieren KI-Modelle die Schlafzeiten und die Schlafqualität extrem zuverlässig durch die Fusion passiver Datenpunkte: Daten der Beschleunigungssensoren (Accelerometer) für die nächtliche Bewegungslosigkeit, Umgebungslichtsensoren und spezifische Zeitstempel, wie die Latenz zwischen dem letzten „Screen-Off“-Ereignis in der Nacht und dem ersten „Screen-On“-Ereignis am Morgen (sogenannte „nocturnal smartphone inactivity duration“).⁶

Bei der Manifestation depressiver Episoden registrieren die Algorithmen in der Regel eine stark erhöhte Latenz beim abendlichen Einschlafen, gekoppelt mit einer ausgedehnten nächtlichen Smartphone-Inaktivität, die auf Hypersomnie oder Antriebslosigkeit hindeutet. Am Tag zeigt sich eine messbare physische Immobilität und eine signifikant reduzierte „Location Entropy“. Die Location Entropy ist ein statistisches Maß für die Vielfalt der besuchten Orte; ein niedriger Wert indiziert, dass der Nutzer die eigene Wohnung kaum noch verlässt und sein geografisches

Verhaltensmuster stark eingeschränkt ist.⁶ Zusätzlich führt der soziale Rückzug zu längeren Antwortlatenzen bei eingehenden Nachrichten und einer Verringerung der ausgehenden Kommunikationsfrequenz.

Bei Patienten mit bipolarer Störung fungiert die digitale Phänotypisierung als hochpräzises Frühwarnsystem für Phasenübergänge. Ein Muster aus drastisch verkürzter Schlafdauer, extrem gesteigerter physischer Mobilität und einer unruhigen, hochfrequenten Interaktion mit dem Smartphone in den späten Nachtstunden ist ein starker prädiktiver Biomarker für eine unmittelbar bevorstehende manische Episode.⁶ Das KI-System bewertet diese Anomalien nicht isoliert, sondern stets relativ zur zuvor berechneten historischen Baseline des individuellen Nutzers.

Generalisierte Angststörungen und psychosozialer Stress

Die Diagnostik von sozialen Phobien und generalisierten Angststörungen durch KI stützt sich primär auf Mikromobilitätsmuster und die Struktur der Geräteinteraktion. Algorithmen identifizieren akute Angstzustände anhand einer signifikant reduzierten Anzahl an absolvierten GPS-Trajektorien (Routen, die im Tagesverlauf zurückgelegt werden) und einer erratischen Veränderung in der Nutzung von Kommunikations-Apps.⁴⁸

Ein charakteristischer Marker für kognitiven Stress und Agitiertheit ist das sogenannte „App-Switching“ oder App-Hopping: Ein Nutzer öffnet das Smartphone, springt in schneller Folge zwischen verschiedenen Applikationen hin und her, ohne sich länger auf einen bestimmten Inhalt zu fokussieren, und sperrt das Gerät wieder.⁶ Wenn ein System gleichzeitig feststellt, dass ein Nutzer ungewöhnlich häufig Benachrichtigungen wegwischt (ignoriert) oder signifikant länger benötigt, um auf Push-Mitteilungen zu reagieren, wird dies in Korrelation mit einer reduzierten physischen Bewegung als belastbares Signal für psychosozialen Stress und kognitive Überforderung interpretiert.⁶ Pilotstudien wie jene mit der *mindLAMP*-Applikation zeigen, dass aus diesen passiven Daten extrahierte Profile eine prädiktive Sensitivität von bis zu 84 % für Angstzustände erreichen.⁴

Schizophrenie und die Prädiktion psychotischer Schübe

Die weitreichendsten Erfolge der digitalen Phänotypisierung zeigen sich in der Präventivmedizin bei Schizophrenie-Patienten. Anomalien im Verhalten, die klinischen Fragebögen oft entgehen, können durch Smartphone-Metadaten bereits Wochen vor einem akuten psychotischen Relapse (Rückfall) detektiert werden.⁶

Die KI-Modelle, wie sie beispielsweise in der *CrossCheck*-Sensing-Umgebung angewendet werden, überwachen die Integrität der täglichen Routinen.⁶ Ein psychotischer Schub kündigt sich typischerweise durch einen gravierenden Verfall der Verhaltensrhythmik an: Schlafzyklen invertieren sich, die Sprache des Nutzers (aufgenommen als reines Audio-Metadatum bezüglich Pausen und Stimmlage, ohne Inhaltstranskription) flacht ab, die physische Aktivität sinkt drastisch, und die Sozialrhythmen erodieren.⁶ Diese Marker spiegeln die für Schizophrenie typische Negativsymptomatik (wie Anhedonie, Alogie und Avolition) wider.⁶ Die Fähigkeit der Algorithmen, diese subtilen, schleichenden Veränderungen durch kontinuierliche Hintergrundüberwachung in Echtzeit zu erkennen, erlaubt es dem medizinischen System,

präventive Interventionen auszulösen, bevor eine klinische Hospitalisierung notwendig wird.⁴²

Räumliche und zeitliche Rekonstruktion: Der ökonomische und soziale Fingerabdruck

Während die bisher diskutierten Methoden tief in die kognitive und medizinische Konstitution des Individuums blicken, aggregieren KI-Systeme räumliche (GPS, Wi-Fi, Funkzellen) und zeitliche Operationsdaten, um hochauflösende sozioökonomische und gesellschaftliche Milieustudien zu generieren. Die einfache Prämisse lautet: An welchen Orten sich ein Nutzer zu welchen Zeiten aufhält, wie sich diese Aufenthaltsorte strukturieren und mit wem diese Orte korrelieren, ist ein extrem valider, unbewusster Prädiktor für Einkommen, Bildungsniveau, gesellschaftlichen Status und sogar politische Präferenzen.

Die Inferierung des Sozioökonomischen Status (SES) aus Mobilität

Die herkömmliche Erhebung des sozioökonomischen Status einer Bevölkerung durch nationale statistische Ämter mittels Zensus und Haushaltsbefragungen (wie der American Community Survey) ist zeit- und kostenintensiv.⁵⁴ Moderne Deep-Learning-Modelle umgehen diesen Aufwand, indem sie den SES direkt aus massenhaften, aggregierten Mobilitätsdaten und Metadaten ableiten. Ein prominentes Beispiel für diese Architektur ist das *DeepSEI*-Modell (Socioeconomic-aware Deep Model), das Merkmale aus Trajektorien auf drei fundamentalen Ebenen extrahiert: räumlich (welche geografischen Zonen durchquert werden), zeitlich (zu welchen Tages- und Nachtzeiten) und aktivitätsbezogen (welche Point of Interest, POIs, frequentiert werden).⁵⁶

Die netzwerktheoretische Analyse dieser Mobilitäts- und Kommunikationsmetadaten fußt stark auf soziologischen Axiomen wie Mark Granoveters Konzept der "Stärke schwacher Bindungen" (Strength of weak ties).⁷ KI-Analysen von Telekommunikationsdaten ganzer Nationen belegen quantitativ, dass Individuen mit einem hohen sozioökonomischen Status in der Regel ein wesentlich breiteres, geografisch diversifizierteres Mobilitäts- und Interaktionsnetzwerk aufweisen. Sie fungieren in Algorithmen als zentrale Knotenpunkte mit einer hohen "Collective Influence" (CI), die verschiedene, ansonsten isolierte soziale Cluster miteinander verbinden.⁷ Ein KI-System kann demnach allein aus der Entropie der besuchten Funkzellen und der Vielfalt der Kommunikationsmuster mit erstaunlicher Genauigkeit das Einkommensniveau, das Vermögen und potenziell die Bonität (Kreditwürdigkeit) eines Nutzers berechnen.⁷

Darüber hinaus demaskiert die isolierte Analyse von GPS-Logfiles tiefgreifende private Attribute. Die Frequenz und die exakte Uhrzeit von Aufenthalten an spezifischen POIs korrelieren stark mit demografischen Variablen. Ein Algorithmus kann durch die Korrelation von nächtlichen Wohnorten mit spezifischen Tagesaufenthalten (z.B. Golfplätzen an Wochenenden, Spielotheken, oder bestimmten Freizeiteinrichtungen) präzise Modelle über das Geschlecht, den Familienstand (z.B. das Zusammenleben mit Kleinkindern) und Konsumgewohnheiten erstellen, ohne jemals Bankdaten einzusehen.⁵⁹ In einer Studie des MIT Senseable City Lab wurden beispielsweise durch maschinelles Lernen (mittels Lasso-Regression und Kreuzvalidierung) Restaurantbesuchsdaten und Mobilfunkstandorte in chinesischen

Metropolen genutzt, um die Bevölkerungsdichte, die Anzahl lokaler Unternehmen und das Konsumvolumen in feinmaschigen Rastern von 1 bis 5 Quadratkilometern hochpräzise vorherzusagen.⁶⁰

Soziales Milieu und Prädiktion des Wahlverhaltens

Die Vorhersagekraft von KI-Systemen beschränkt sich nicht auf ökonomische Variablen, sondern extrapoliert auf politische und ideologische Milieus. Durch die intelligente Fusion von Geolocation-Daten mit Computer-Vision-Algorithmen lassen sich aus öffentlich verfügbaren, scheinbar neutralen Datenbergen intime gesellschaftliche Profile erstellen.

In einer vielbeachteten Untersuchung nutzten Forscher Deep-Learning-Algorithmen, um über 50 Millionen Bilder von Google Street View aus 200 US-Städten zu analysieren.⁵⁴ Die KI identifizierte Marke, Modell und Baujahr von 22 Millionen geparkten Fahrzeugen in spezifischen Postleitzahlengebieten. Aus dieser Zählung von Fahrzeugen wurden präzise Assoziationen zu Einkommen, ethnischer Zugehörigkeit, Bildungsstand und – am brisantesten – zum politischen Wahlverhalten abgeleitet. Das Modell stellte fest, dass in einer Nachbarschaft, in der die Anzahl von Limousinen (Sedans) die Anzahl von Pick-up-Trucks übersteigt, eine 88%ige Wahrscheinlichkeit besteht, dass dieser Wahlbezirk bei der nächsten Präsidentschaftswahl für die Demokratische Partei stimmt. Im umgekehrten Fall wählte der Bezirk mit 82%iger Wahrscheinlichkeit republikanisch.⁵⁴

Werden solche geografischen Makrodaten mit den individuellen, tagesaktuellen App-Nutzungszeiten eines Nutzers kombiniert, entsteht ein hochkomplexes "Contextual AI"-Profil. Der Algorithmus kennt dann nicht nur den Wohnort und das wahrscheinliche Milieu des Nutzers, sondern berechnet auf Basis von externen Faktoren (wie aktuellen Wetterbedingungen) und historischen App-Aktivitäten den akuten emotionalen oder bedürfnisorientierten Kontext, in dem sich die Person in genau dieser Minute befindet.⁶²

Datenquelle / Sensortyp	Extrahierte Metadaten	Algorithmische Inferierung (Profiling)
GPS / Mobilfunkzellen	Geografische Entropie, Vielfalt der aufgesuchten Orte. ⁷	Sozioökonomischer Status, Vermögensverteilung, Kreditwürdigkeit.
Point of Interest (POI) Logs	Frequenz von Stopps an spezifischen Orten, Zeiten. ⁵⁹	Familienstand (Kinder im Haushalt), Hobbys, Geschlecht, Suchtverhalten.
Computer Vision (Street View)	Objekterkennung (z.B. Fahrzeugtypen in der Nachbarschaft). ⁵⁴	Politisches Wahlverhalten, Bildungsniveau, ethnische Demografie.
Kontextuelle Sensoren	Kombination aus Standort, Wetter, Tageszeit und App-Aktivität. ⁶²	Temporärer emotionaler Zustand, akute Konsumbedürfnisse (z.B. Food-Delivery).

Kommerzielle Verwertung und algorithmische Überwachung

Die Fähigkeit moderner KI-Modelle, aus unbewussten, non-sensiblen Metadaten hochsensible, multidimensionale Profile zu synthetisieren, hat massive technologische und ökonomische Implikationen. Industrien adaptieren diese Technologien rasant, um Prozesse zu optimieren, Risiken zu minimieren und Konsumenten granularer zu steuern – oft völlig unsichtbar für den Endverbraucher.

Zero-Trust-Architekturen und Kontinuierliche Authentifizierung

Im Sektor der Cybersicherheit revolutioniert die Verhaltensbiometrie das fundamentale Konzept der Authentifizierung. Konventionelle Methoden (wie Passwörter, PINs oder physische biometrische Scans via Fingerabdruck oder Face-ID) verifizieren die Identität eines Nutzers lediglich statisch am Beginn einer Sitzung. Moderne, von KI getriebene "Zero-Trust"-Architekturen und "User and Entity Behavior Analytics" (UEBA)-Systeme implementieren hingegen eine ununterbrochene, unsichtbare *kontinuierliche* Authentifizierung im Hintergrund.⁶⁴

Diese Systeme aggregieren die Tippgeschwindigkeit, die Rhythmik der Pausen, die Verwendung spezifischer Tastaturkürzel (Shortcuts), den Druck und die Wischwinkel auf Touchscreens sowie die Pfadabweichungen von Mausbewegungen zu einer dynamischen, einzigartigen Verhaltenssignatur.² Maschinelle Lernmodelle (wie Multi-Layer Perceptrons für Tastaturdaten und Decision Trees für Mausdaten) erreichen hierbei extreme Präzision mit einer Equal Error Rate (EER) von teils unter 1,26 % bzw. 0,43 %.¹⁵

Weicht das Verhalten des aktiven Nutzers auch nur für wenige Sekunden von seiner durch neuronale Netze gelernten historischen Baseline ab – beispielsweise weil ein physischer Angreifer den ungesperrten Laptop übernommen hat, oder weil ein automatisiertes Skript (Bot) agiert –, passt das System den "Dynamic Trust Score" an und entzieht im Zweifelsfall sofort die Zugriffsrechte.²³ Im Finanzsektor detektieren diese Systeme Betrugsversuche durch Social Engineering (z.B. den sogenannten Enkeltrick oder CEO-Fraud). Wenn Betrüger ein Opfer telefonisch fernsteuern, während dieses eine Überweisung tätigt, erkennen die Algorithmen untypisches Zögern bei der Mausführung, ungewohnte Copy-Paste-Muster oder atypische Latenzen bei der Dateneingabe, die nicht zum kognitiven Standardprofil des legitimen Kontoinhabers passen, und blockieren die Transaktion proaktiv.²³

Prädiktives Marketing, Emotional Sequencing und Risikobewertung

In der Werbe- und E-Commerce-Industrie fließen die durch digitale Phänotypisierung inferierten Daten direkt in die automatisierte Steuerung von Kampagnen ein. Das Konzept des "Contextual AI" zielt darauf ab, Konsumenten nicht nur anhand statischer Zielgruppen, sondern anhand ihres fluktuierenden emotionalen und kognitiven Zustands in Echtzeit anzusprechen.⁶² Psychologische Forschungen belegen, dass das Nutzerverhalten stark kontextabhängig ist. So korrelieren schlechte Wetterbedingungen, die das Ausgehen erschweren, gekoppelt mit

spezifischen App-Nutzungsmustern, mit einer erhöhten Empfänglichkeit für Food-Delivery-Werbung.⁶³ Noch brisanter wird das algorithmische Targeting durch "Emotional Sequencing": Studien (wie die der Yale School of Management) zeigen, dass KI-gestützte Empfehlungssysteme berücksichtigen müssen, wie Nutzer auf emotionale Reize reagieren.⁷¹ Konsumenten, die gerade traurige oder moralisch belastende Inhalte konsumiert haben (erkennbar an Verweildauer, Scrollverhalten und Lese-Latenzen), verspüren oft unbewusst das Bedürfnis, diesen melancholischen Zustand kurzzeitig aufrechtzuerhalten, und reagieren extrem negativ auf plötzliche, unangemessen fröhliche Werbeinhalte.⁷¹ Die Algorithmen passen die Ausspielung des Inhalts daher an die unbewusste emotionale Trajektorie des Nutzers an. Ebenso disruptiv agiert die KI in der Versicherungsbranche beim automatisierten "Risk Assessment" (Risikobewertung). Anstatt Prämien und Deckungszusagen primär an statische demografische Tabellen zu koppeln, werten KI-Agenten das kontinuierliche Verhalten aus.⁷² Forschungen zur Arbeitspsychologie und Kognitionswissenschaft belegen starke Korrelationen zwischen alltäglichen Verhaltensdaten und komplexen kognitiven Fähigkeiten. So korreliert die Tippgeschwindigkeit und die Präzision des Vorrasschauens beim Schreiben (Eye-Hand Span) hochgradig mit der kognitiven Leistungsfähigkeit und der exekutiven Kontrolle.¹⁹ Algorithmen nutzen Wearable-Daten, Smartphone-Telemetrie und solche mikro-verhaltensbasierten Metriken, um Risikoprofile für Kranken- oder Lebensversicherungen in Echtzeit neu zu berechnen, wodurch der Nutzer durch jede unbewusste Interaktion mit seinem Gerät seinen eigenen ökonomischen Wert auf dem Markt kontinuierlich selbst taxiert.⁷³

Datenschutzrechtliche Krisen und das ethische Vakuum: Der Gläserne Nutzer

Die rasante technologische Diskrepanz zwischen der scheinbaren Banalität der erhobenen Rohdaten (wie Millisekunden eines Tastendrucks, GPS-Pings oder die Dauer einer Bildschirmaktivierung) und der extremen Sensibilität der daraus durch Deep Learning synthetisierten Profile (z.B. eine drohende Parkinson-Diagnose, ein hohes Suizidrisiko, eine depressive Episode oder die exakte politische Orientierung) erzeugt ein massives juristisches, datenschutzrechtliches und philosophisches Vakuum.⁷⁶

Die Anatomie der "Inference Attacks" und Privacy by Proxy

In der Terminologie der IT-Sicherheit und des maschinellen Lernens wird das unautorisierte Extrahieren sensibler Informationen aus den Ausgaben oder der Struktur von KI-Modellen als "Inference Attack" (Rückschluss-Angriff) bezeichnet.³ Man unterscheidet hierbei primär zwischen *Membership Inference Attacks* (die feststellen, ob die Daten einer spezifischen Person zum Training eines Modells verwendet wurden) und *Property Inference Attacks* (die globale, aber sensible Eigenschaften einer Datenkohorte extrahieren, die der Modellentwickler möglicherweise gar nicht freigeben wollte).⁷⁹

Wenn beispielsweise ein Modell im Rahmen von föderiertem Lernen (Federated Learning) auf einem Smartphone trainiert wird, um das lokale App-Verhalten zu optimieren, kann ein Property Inference Attack aus den Parametern des Modells hochsensible Attribute des

Smartphone-Besitzers ableiten, ohne jemals direkten Zugriff auf die Rohdaten (wie Fotos oder Chatverläufe) gehabt zu haben.⁷⁹ Zudem besteht das akute Risiko der *Cross-Device Inference*, bei der scheinbar anonyme Datenfragmente von verschiedenen Geräten im Internet der Dinge (IoT) durch KI fusioniert werden, um ein detailliertes Schattenprofil des Nutzers zu rekonstruieren, ohne dass dieser jemals eine direkte Verbindung zwischen den Geräten autorisiert hat.³

Dieser algorithmische Mechanismus stellt die Definition von "personenbezogenen Daten" im Rahmen der etablierten Gesetzgebung, insbesondere der europäischen Datenschutz-Grundverordnung (DSGVO) und des California Consumer Privacy Act (CCPA), vor fundamentale konzeptionelle Probleme.⁷⁷ Die DSGVO klassifiziert Gesundheitsdaten, politische Meinungen und genetische sowie biometrische Daten zur eindeutigen Identifizierung als besonders schützenswerte Kategorien (Art. 9 DSGVO).⁸¹ Die Gesetzgebung ist jedoch historisch darauf ausgerichtet, die aktive *Erhebung* und *Speicherung* explizit identifizierender Daten zu regulieren.³

Wenn eine KI jedoch aus völlig "harmlosen" Telemetriedaten (wie dem Zeitstempel der nächtlichen Smartphone-Nutzung und dem Gyroskop-Winkel) durch statistische Korrelation inferiert, dass der Nutzer mit hoher Wahrscheinlichkeit an einer bipolaren Störung leidet, wird eine scheinbar neutrale Information faktisch zu einem hochsensiblen Gesundheitsdatum. Dieses Phänomen wird juristisch als "Privacy by Proxy" oder "abgeleitete Identität" diskutiert.⁸⁰ Ein Nutzer mag einer Cookie-Richtlinie oder den AGBs (Terms of Service) einer App zustimmen, die das Tracken von Mausclicks auf einer E-Commerce-Seite legitimiert – er stimmt damit nach Geist und Buchstabe des Gesetzes jedoch nicht bewusst einer tiefenpsychologischen oder medizinischen Profilierung zu. Dennoch extrapolieren Frontier-Modelle und Large Language Models (LLMs), wie Analysen von Datenschutzrichtlinien führender Entwickler zeigen, ununterbrochen demografische, psychologische und beziehungstechnische Daten aus den unbedachten Dialogen und Interaktionen der Nutzer, um ihre Trainingskorpora zu speisen.¹

Digitale Autonomie und das Recht auf "Reasonable Inferences"

Die massenhafte, oft unsichtbare Anwendung von IBP berührt die philosophischen Grundfesten der digitalen Selbstbestimmung und der informationellen Autonomie.⁷⁸ Ein "gläserner Nutzer" entsteht in diesem neuen Paradigma nicht dadurch, dass er fahrlässig all seine Geheimnisse, Passwörter und intimsten Gedanken freiwillig in sozialen Netzwerken preisgibt. Er entsteht vielmehr dadurch, dass seine physiologische und kognitive Maschinerie – das Herz-Kreislauf-System, das zentrale Nervensystem, der Stoffwechsel – zwangsläufig digitale Abdrücke in der physischen Interaktion mit der vernetzten Welt hinterlässt, die er als biologisches Wesen gar nicht willentlich unterdrücken kann.⁷⁸

Eine Parkinson-bedingte Asymmetrie beim Tippen, eine durch Angststörungen getriebene erratische App-Navigation oder die durch Schlaflosigkeit verzerrten Nutzungszeiten sind unwillkürliche biologische und psychologische Reaktionen.²⁹ Die kommerzielle Ausbeutung solcher abgeleiteten Daten für "Surveillance Pricing" (algorithmisch personalisierte Preisbildung), für diskriminierendes Scoring auf dem Arbeits-, Versicherungs- oder Wohnungsmarkt oder für subtile emotionale Manipulation durch "Emotional AI" (die Erkennung

und Ausnutzung von Verletzlichkeit) birgt unkalkulierbare Risiken für das Individuum und die Gesellschaft.³

Rechtsgelehrte, Ethikkommissionen und Datenschutzexperten fordern daher zunehmend die Implementierung eines fundamentalen Rechts auf "vernünftige algorithmische Rückschlüsse" (A Right to Reasonable Inferences). Dieses rechtliche Konstrukt würde es KI-Systemen untersagen, tiefgreifende, potenziell diskriminierende oder stark in die Persönlichkeit eingreifende gesundheitliche, philosophische oder politische Schlüsse zu ziehen, sofern diese nicht direkt, explizit und absolut transparent durch den Nutzer für genau diesen spezifischen Zweck autorisiert wurden und zudem das Risiko für signifikante Schäden ("significant harm test") ausgeschlossen ist.⁷⁸ Die Verhinderung derartiger invasiver Profilings wird massiv dadurch erschwert, dass große Technologiekonzerne die Funktionsweise ihrer algorithmischen "Black Boxes" durch Geschäftsgeheimnisse (Trade Secrets) und strenge Non-Disclosure Agreements (NDAs) abschirmen, was oft nur durch mutige Whistleblower aufgedeckt wird, die erhebliche persönliche Risiken eingehen.⁸⁷

Synthese und Ausblick: Die Grenzen der menschlichen Opazität

Die rasante Evolution der Künstlichen Intelligenz und des maschinellen Lernens hat das Zeitalter der rein semantischen Überwachung – in der primär der Inhalt von Nachrichten und Suchanfragen analysiert wurde – unwiderruflich beendet und die Ära der tiefgreifenden verhaltensbiometrischen und digitalen phänotypischen Analyse eingeläutet. KI-Systeme benötigen längst keine direkten, bewussten Antworten mehr auf sensible Fragen, um ein Individuum bis in seine intimsten kognitiven und biologischen Strukturen hinein zu durchleuchten.

Die Kadenz, mit der ein Text verfasst wird, die Mikrosekunden, die ein Finger zögernd auf einer Taste verweilt, die spezifischen orthografischen Inkonsistenzen und phonemischen Anomalien, die tägliche geografische Entropie der Mobilität sowie die Ladegewohnheiten und Bildschirmaktivierungszyklen eines Smartphones formen ein unendlich dichtes, ununterbrochenes Netz an Informationen. Aus diesen passiven Datenabgasen destillieren Deep-Learning-Algorithmen hochpräzise, multidimensionale Profile, die den kognitiven, emotionalen, demografischen und sozioökonomischen Zustand eines Nutzers gnadenlos offenlegen.

Sie identifizieren den schleichenden Beginn schwerer neurologischer Erkrankungen wie Alzheimer oder Morbus Parkinson oft Jahre vor der ersten klinischen Diagnose, sie quantifizieren das akute Risiko für psychotische Rückfälle bei Schizophrenie-Patienten, und sie kartografieren den sozialen Status und die politischen Präferenzen ganzer Stadtteile mit einer Vorhersagegenauigkeit, die konventionellen demografischen Erhebungsmethoden weit überlegen ist. Diese immensen analytischen Fähigkeiten demonstrieren zweifellos ein enormes, potenziell lebensrettendes Potenzial für die individualisierte Medizintechnik, die präventive Psychiatrie, die adaptive Mensch-Maschine-Interaktion und den Schutz vor Cyberkriminalität durch Zero-Trust-Architekturen.

Gleichzeitig jedoch offenbaren sie ein fundamental neues, invasives Überwachungsparadigma, das traditionelle, auf der bewussten Dateneingabe basierende Datenschutzmechanismen ad absurdum führt. Da der Mensch aufhört, lediglich aktiver Datenproduzent zu sein, und stattdessen durch sein bloßes biologisches und physikalisches Dasein im digitalen Raum wie ein offenes Buch ausgelesen wird, bedarf es einer dringenden technologischen, juristischen und philosophischen Neukalibrierung. Ohne strikte gesetzliche Regulierungen gegen unautorisierte "Inference Attacks", ohne das juristisch einklagbare Recht auf Schutz vor algorithmischen Rückschlüssen ("Reasonable Inferences") und ohne zwingende Transparenz bei der Risikobewertung verschwimmt die Grenze zwischen hilfreicher medizinischer oder kommerzieller Personalisierung und einer unsichtbaren, totalitären Entschlüsselung des menschlichen Geistes. Der Schutz der Privatsphäre im Zeitalter der Künstlichen Intelligenz darf sich nicht länger nur auf die Verteidigung der Rohdaten beschränken, sondern muss die algorithmischen Rückschlüsse und die maschinelle Prädiktion selbst in das absolute Zentrum der zukünftigen Regulation rücken.

Referenzen

1. Inference-Based Privacy Violations Demand Immediate Recognition as a Distinct AI Safety Priority | OpenReview, Zugriff am April 3, 2026, <https://openreview.net/forum?id=gllqPel6w5>
2. What is Behavioral Biometrics - LexisNexis Risk Solutions, Zugriff am April 3, 2026, <https://risk.lexisnexis.com/insights-resources/article/what-is-behavioral-biometrics>
3. Both ends of artificial intelligence impacting privacy: a review of violation and protection, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12957209/>
4. Digital phenotyping: how it could change mental health care and why we should all keep up, Zugriff am April 3, 2026, <https://www.tandfonline.com/doi/full/10.1080/09638237.2024.2395537>
5. Keystroke-Dynamics for Parkinson's Disease Signs Detection in An At-Home Uncontrolled Population: A New Benchmark and Method - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC9904385/>
6. Digital Phenotyping for Monitoring Mental Disorders: Systematic Review, Zugriff am April 3, 2026, <https://www.jmir.org/2023/1/e46778/>
7. Inferring personal economic status from social network location - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC5440802/>
8. Age and Gender as Cyber Attribution Features in Keystroke Dynamic-Based User Classification Processes - MDPI, Zugriff am April 3, 2026, <https://www.mdpi.com/2079-9292/10/7/835>
9. Exploring Age-Related Patterns in Smartphone Keystroke Dynamics Considering Temporal Variability: Cross-Sectional Study With AI-Based Analysis - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12709153/>
10. The influence of emotion on keyboard typing: an experimental study using visual stimuli, Zugriff am April 3, 2026,

- <https://pmc.ncbi.nlm.nih.gov/articles/PMC4091769/>
11. What Is Behavioral Biometrics: How Does It Work Against Fraud - Feedzai, Zugriff am April 3, 2026, <https://www.feedzai.com/blog/behavioral-biometrics-next-generation-fraud-prevention/>
 12. IKDD: A Keystroke Dynamics Dataset for User Classification - MDPI, Zugriff am April 3, 2026, <https://www.mdpi.com/2078-2489/15/9/511>
 13. User attribution through keystroke dynamics-based author age estimation - Bournemouth University, Zugriff am April 3, 2026, [https://eprints.bournemouth.ac.uk/36304/1/1.%20User Attribution through Keystroke Dynamics-Based Author Age Estimation %28final%29.pdf](https://eprints.bournemouth.ac.uk/36304/1/1.%20User%20Attribution%20through%20Keystroke%20Dynamics-Based%20Author%20Age%20Estimation%28final%29.pdf)
 14. Predicting Age and Gender by Keystroke Dynamics and Mouse Patterns - ResearchGate, Zugriff am April 3, 2026, https://www.researchgate.net/publication/317400387_Predicting_Age_and_Gender_by_Keystroke_Dynamics_and_Mouse_Patterns
 15. User authentication through behavioral biometrics using multi-class classification algorithms - kth .diva, Zugriff am April 3, 2026, <https://kth.diva-portal.org/smash/get/diva2:1846194/FULLTEXT01.pdf>
 16. A Review of Emotion Recognition Methods From Keystroke, Mouse, and Touchscreen Dynamics, Zugriff am April 3, 2026, https://researchportal.northumbria.ac.uk/files/65202879/Final_published_version.pdf
 17. Keystroke Dynamics Patterns While Writing Positive and Negative Opinions - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC8434638/>
 18. Computational emotion analysis with multimodal LLMs Current evidence on an emerging methodological opportunity - arXiv, Zugriff am April 3, 2026, <https://arxiv.org/html/2512.10882v2>
 19. A Review on Smartphone Keystroke Dynamics as a Digital Biomarker for Understanding Neurocognitive Functioning - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC10296416/>
 20. Identifying Users' Emotional States through Keystroke Dynamics - SciTePress, Zugriff am April 3, 2026, <https://www.scitepress.org/Papers/2022/113673/113673.pdf>
 21. Predicting Mood Disturbance Severity with Mobile Phone Keystroke Metadata: A BiAffect Digital Phenotyping Study - Journal of Medical Internet Research, Zugriff am April 3, 2026, <https://www.jmir.org/2018/7/e241/>
 22. Detection of Mental Fatigue in the General Population: Feasibility Study of Keystroke Dynamics as a Real-world Biomarker - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC11041424/>
 23. What is Behavioral Biometrics? - OneSpan, Zugriff am April 3, 2026, <https://www.onespan.com/topics/behavioral-biometrics>
 24. Diagnosis by keyboard | MIT News | Massachusetts Institute of Technology, Zugriff am April 3, 2026, <https://news.mit.edu/2015/typing-patterns-diagnose-early-onset-parkinsons-0401>

25. Making too many spelling mistakes lately? Scientists say it could be the earliest signs of dementia | - The Times of India, Zugriff am April 3, 2026, <https://timesofindia.indiatimes.com/life-style/health-fitness/health-news/making-too-many-spelling-mistakes-lately-scientists-say-it-could-be-the-earliest-signs-of-dementia/articleshow/125013461.cms>
26. Reduced habit-driven errors in Parkinson's Disease - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC6399280/>
27. Writing the Future: Artificial Intelligence, Handwriting, and Early Biomarkers for Parkinson's Disease Diagnosis and Monitoring - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12292237/>
28. (PDF) Reduced habit-driven errors in Parkinson's Disease - ResearchGate, Zugriff am April 3, 2026, https://www.researchgate.net/publication/331499579_Reduced_habit-driven_errors_in_Parkinson's_Disease
29. High-accuracy detection of early Parkinson's Disease using multiple characteristics of finger movement while typing - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC5708704/>
30. Detection of Mild Cognitive Impairment Through Natural Language and Touchscreen Typing Processing - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC8521910/>
31. AI pen could help detect Parkinson's disease from handwriting - Scimex, Zugriff am April 3, 2026, <https://www.scimex.org/newsfeed/ai-pen-could-help-detect-parkinsons-disease-from-handwriting>
32. Comparison between oral and written spelling in Alzheimer's disease - PubMed, Zugriff am April 3, 2026, <https://pubmed.ncbi.nlm.nih.gov/8866054/>
33. The Heterogeneity of Reading and Spelling Deficits in Posterior Cortical Atrophy - MDPI, Zugriff am April 3, 2026, <https://www.mdpi.com/2076-3425/15/11/1154>
34. Automated text-level semantic markers of Alzheimer's disease - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC8759093/>
35. Spelling and attention in early Alzheimer's disease: evidence for impairment of the graphemic buffer - PubMed, Zugriff am April 3, 2026, <https://pubmed.ncbi.nlm.nih.gov/7640965/>
36. Hearing this speech pattern is a clear indicator that a person is in cognitive decline, Zugriff am April 3, 2026, <https://www.earth.com/news/word-finding-difficulty-wfd-speech-pattern-indication-cognitive-decline/>
37. AI Reveals Distinct Speech Patterns in Parkinson's Disease Patients - Neuroscience News, Zugriff am April 3, 2026, <https://neurosciencenews.com/speech-parkinsons-ai-23221/>
38. Language Markers of Dementia and Their Role in Early Diagnosis of Alzheimer's Disease: Exploring Grammatical and Syntactic Competence via Sentence Repetition - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC11305841/>
39. Full article: Grammatical complexity and productivity in written text in

- presymptomatic frontotemporal dementia: A repeated measures study - Taylor & Francis, Zugriff am April 3, 2026, <https://www.tandfonline.com/doi/full/10.1080/17549507.2025.2602580>
40. Idea Density and Grammatical Complexity as Neurocognitive Markers - PMC - NIH, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12468128/>
 41. Digital Phenotyping in Psychiatry: What Clinical Evidence Reveals in 2025 - GlobalRPH, Zugriff am April 3, 2026, <https://globalrph.com/2025/12/digital-phenotyping-in-psychiatry-what-clinical-evidence-reveals-in-2025/>
 42. Forecasting mental states in schizophrenia using digital phenotyping data, Zugriff am April 3, 2026, <https://journals.plos.org/digitalhealth/article?id=10.1371/journal.pdig.0000734>
 43. Digital Phenotyping for Adolescent Mental Health: Feasibility Study Using Machine Learning to Predict Mental Health Risk From Active and Passive Smartphone Data - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12871944/>
 44. Key Features of Digital Phenotyping for Monitoring Mental Disorders: Systematic Review, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12588392/>
 45. Key Features of Digital Phenotyping for Monitoring Mental Disorders: Systematic Review, Zugriff am April 3, 2026, <https://www.jmir.org/2025/1/e77331/PDF>
 46. Smartphone Usage Patterns and Sleep Behavior in Demographic Groups: Retrospective Observational Study, Zugriff am April 3, 2026, <https://www.jmir.org/2025/1/e60423/>
 47. The power of digital data: Using AI to predict mental health states based on digital phenotyping - UCL Reflect - University College London, Zugriff am April 3, 2026, <https://reflect.ucl.ac.uk/pals-msci-placement-projects/2023/05/28/the-power-of-digital-data-using-ai-to-predict-mental-health-states-based-on-digital-phenotyping/>
 48. Using Smartphone-Tracked Behavioral Markers to Recognize Depression and Anxiety Symptoms: Cross-Sectional Digital Phenotyping Study - PubMed, Zugriff am April 3, 2026, <https://pubmed.ncbi.nlm.nih.gov/41589818/>
 49. Harnessing Digital Phenotyping for Early Self-Detection of Psychological Distress - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12386097/>
 50. Assessing Digital Phenotyping for App Recommendations and Sustained Engagement: Cohort Study - JMIR Formative Research, Zugriff am April 3, 2026, <https://formative.jmir.org/2024/1/e62725>
 51. Utility of Digital Phenotyping Based on Wrist Wearables and Smartphones in Psychosis: Observational Study - JMIR mHealth and uHealth, Zugriff am April 3, 2026, <https://mhealth.jmir.org/2025/1/e56185>
 52. Evaluating the utility of digital phenotyping to predict health outcomes in schizophrenia: protocol for the HOPE-S observational study - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC8529971/>
 53. Using Smartphone-Based Digital Phenotyping to Predict Relapse in Serious

- Mental Disorders Among Slum Residents in Dhaka, Bangladesh: Protocol for a Machine Learning Study - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12872212/>
54. Using deep learning and Google Street View to estimate the demographic makeup of neighborhoods across the United States | PNAS, Zugriff am April 3, 2026, <https://www.pnas.org/doi/10.1073/pnas.1700035114>
 55. Topic Models to Infer Socio-Economic Maps, Zugriff am April 3, 2026, <https://cdn.aaai.org/ojs/9892/9892-13-13420-1-2-20201228.pdf>
 56. [2211.08200] On Inferring User Socioeconomic Status with Mobility Records - arXiv, Zugriff am April 3, 2026, <https://arxiv.org/abs/2211.08200>
 57. Predicting Poverty And Wealth From Mobile Phone Metadata - eScience Institute, Zugriff am April 3, 2026, <https://escience.washington.edu/predicting-poverty-and-wealth-from-mobile-phone-metadata/>
 58. Predicting Poverty and Wealth with Mobile Phone Metadata – GOL - Global Opportunity Lab, Zugriff am April 3, 2026, <https://gol.berkeley.edu/portfolio/predicting-poverty-and-wealth-with-mobile-phone-metadata/>
 59. Estimation of socioeconomic attributes from location information - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC7271143/>
 60. Machine Learning to Predict Socio-Economic Data - urban ai, Zugriff am April 3, 2026, <https://urbanai.fr/machine-learning-to-predict-socio-economic-data/>
 61. Machine Learning to Predict Socio-Economic Data | by Urban AI - Medium, Zugriff am April 3, 2026, <https://medium.com/urban-ai/machine-learning-to-predict-socio-economic-data-d4175f7548a7>
 62. Contextual AI: What It Is and How It Works - Teradata, Zugriff am April 3, 2026, <https://www.teradata.com/insights/ai-and-machine-learning/what-is-contextual-ai>
 63. In search of time to bring the message on social media: Effects of temporal targeting and weather on digital consumers - PMC, Zugriff am April 3, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC9714564/>
 64. What is Behavioral Biometrics? | IBM, Zugriff am April 3, 2026, <https://www.ibm.com/think/topics/behavioral-biometrics>
 65. (PDF) AI-Powered Behavioral Biometrics for Zero Trust Authentication - ResearchGate, Zugriff am April 3, 2026, https://www.researchgate.net/publication/396744666_AI-Powered_Behavioral_Biometrics_for_Zero_Trust_Authentication
 66. AI-Driven Adaptive Authentication Using Behavioral Biometrics and Context-Aware Risk Scoring - iarjset, Zugriff am April 3, 2026, <https://iarjset.com/wp-content/uploads/2025/11/IARJSET.2025.1211031-ai.pdf>
 67. (PDF) AI-Driven Insider Threat Detection Using Behavioral Biometrics - ResearchGate, Zugriff am April 3, 2026, https://www.researchgate.net/publication/396203174_AI-Driven_Insider_Threat_Detection_Using_Behavioral_Biometrics

68. AI-based Identity Fraud Detection: A Systematic Review - arXiv, Zugriff am April 3, 2026, <https://arxiv.org/html/2501.09239v1>
69. What are Behavioral Biometrics? Types & Technology | Okta, Zugriff am April 3, 2026, <https://www.okta.com/identity-101/behavioral-biometrics/>
70. Using Behavioural Biometrics to Combat Social Engineering Voice Scams And App Fraud | BioCatch, Zugriff am April 3, 2026, <https://www.biocatch.com/resources/data-sheets/using-behavioural-biometrics-to-combat-vishing-and-app-fraud>
71. Consumers as Humans: Why Marketers Should Be Thinking About Ads as Part of a Sequence | Yale School of Management, Zugriff am April 3, 2026, <https://som.yale.edu/story/2022/consumers-humans-why-marketers-should-be-thinking-about-ads-part-sequence>
72. AI-Driven Insurance Pricing 2024 | AI Agents with Machine Learning - Rapid Innovation, Zugriff am April 3, 2026, <https://www.rapidinnovation.io/post/ai-powered-insurance-pricing-models>
73. Smarter Risk Assessment with AI Agents in Insurance Underwriting - Newgen, Zugriff am April 3, 2026, <https://newgensoft.com/resources/article/smarter-risk-assessment-with-ai-agents-in-insurance-underwriting/>
74. A Deliberate Practice Account of Typing Proficiency in Everyday Typists - Humanwissenschaften – TU Darmstadt, Zugriff am April 3, 2026, https://www.humanw.tu-darmstadt.de/media/orgpsy/keithericsson2007_preprint.pdf
75. How data analytics is revolutionizing psychology | Penn LPS Online, Zugriff am April 3, 2026, <https://lponline.sas.upenn.edu/features/how-data-analytics-revolutionizing-psychology>
76. Privacy in an AI Era: How Do We Protect Our Personal Information? | Stanford HAI, Zugriff am April 3, 2026, <https://hai.stanford.edu/news/privacy-ai-era-how-do-we-protect-our-personal-information>
77. The growing data privacy concerns with AI: What you need to know - DataGuard, Zugriff am April 3, 2026, <https://www.dataguard.com/blog/growing-data-privacy-concerns-ai/>
78. Biometric Recognition and Behavioural Detection. - European Parliament, Zugriff am April 3, 2026, [https://www.europarl.europa.eu/RegData/etudes/STUD/2021/696968/IPOL_STU\(2021\)696968_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2021/696968/IPOL_STU(2021)696968_EN.pdf)
79. How Worrying Are Privacy Attacks Against Machine Learning? - arXiv, Zugriff am April 3, 2026, <https://arxiv.org/html/2511.10516v1>
80. Privacy by proxy: Regulating inferred identities in AI systems - IAPP, Zugriff am April 3, 2026, <https://iapp.org/news/a/privacy-by-proxy-regulating-inferred-identities-in-ai-systems>
81. KI & Datenschutz in der EU: Rahmen, Rollen, Orientierung - Althammer & Kill,

- Zugriff am April 3, 2026,
<https://www.althammer-kill.de/aktuelles/news/detail/ki-und-datenschutz-in-der-eu>
82. Behavioural profiling for age assurance: do the ends justify the means? - Oxford Academic, Zugriff am April 3, 2026,
<https://academic.oup.com/idpl/advance-article/doi/10.1093/idpl/ipaf012/8327959>
 83. Study exposes privacy risks of AI chatbot conversations | Stanford Report, Zugriff am April 3, 2026,
<https://news.stanford.edu/stories/2025/10/ai-chatbot-privacy-concerns-risks-research>
 84. Gutachten der Datenethikkommission - Kurzfassung - Bundesministerium des Innern, Zugriff am April 3, 2026,
https://www.bmi.bund.de/SharedDocs/downloads/DE/publikationen/themen/it-digitalpolitik/gutachten-datenethikkommission-kurzfassung.pdf?__blob=publicationFile&v=4
 85. PRESS RELEASE: Report: Privacy Harms from AI Necessitate Robust Risk Assessments, Zugriff am April 3, 2026,
<https://epic.org/press-release-report-privacy-harms-from-ai-necessitate-robust-risk-assessments/>
 86. Examining Privacy Risks in AI Systems | Transcend | The compliance layer for customer data, Zugriff am April 3, 2026, <https://transcend.io/blog/ai-and-privacy>
 87. The Promise and Perils of Tech Whistleblowing - Texas A&M Law Scholarship, Zugriff am April 3, 2026,
https://scholarship.law.tamu.edu/context/facscholar/article/2971/viewcontent/The_Promise_and_Perils_of_Tech_Whistleblowing.pdf
 88. Big Tech Accountability Depends on Better Protection for Whistleblowers - The Signals Network, Zugriff am April 3, 2026,
<https://thesignalsnetwork.org/wp-content/uploads/2024/03/Big-Tech-Accountability-Depends-on-Better-Protection-for-Whistleblowers.pdf>
 89. Leaking black boxes: Whistleblowing and big tech invisibility - First Monday, Zugriff am April 3, 2026,
<https://firstmonday.org/ojs/index.php/fm/article/download/12670/10751>