

MATHIAS VUKELIĆ | KATHARINA LINGELBACH | DANIELA PIECHNIK

FEINFÜHLIGE TECHNIK

WIE NEUROERGONOMIE UND BRAIN-COMPUTER-INTERFACES IN DER PRAXIS
EINGESETZT WERDEN KÖNNEN

HRSG.: WILHELM BAUER | OLIVER RIEDEL | THOMAS RENNER | MATTHIAS PEISSNER





Mathias Vukelić, Katharina Lingelbach, Daniela Piechnik

FEINFÜHLIGE TECHNIK

Wie Neuroergonomie und Brain-Computer-Interfaces in der Praxis eingesetzt werden können

Herausgeber

Wilhelm Bauer, Oliver Riedel, Thomas Renner, Matthias Peissner

VORWORT

Künstliche Intelligenz (KI) ist eine der zentralen Technologien für die Zukunft. Ihre Einführung und der Einsatz fordern Unternehmen im besonderen Maß heraus. Es gilt, das Potenzial zu erkennen und dieses wirtschaftlich nutzbar zu machen. Lassen Sie sich dabei durch Europas größte Forschungsk Kooperation auf dem Gebiet der KI, Cyber Valley, begleiten.

Mit dem KI-Fortschrittszentrum von Fraunhofer IAO und Fraunhofer IPA unterstützen wir Unternehmen dabei, das Potenzial von KI nutzbringend einzusetzen. An der Schnittstelle zwischen anwendungsorientierter Wirtschaft und exzellenter Forschung des Cyber-Valley-Konsortiums entwickeln wir innovative KI-Anwendungen für die Praxis und treiben damit die Kommerzialisierung von KI voran. Erklärtes Ziel ist dabei, menschenzentrierte KI-Lösungen zu entwickeln. Denn nur wenn Menschen mit einer neuen Technologie intuitiv interagieren und vertrauensvoll zusammenarbeiten, kann ihr Potenzial optimal ausgeschöpft werden.

Die Studienreihe »Lernende Systeme« des KI-Fortschrittszentrums gibt Einblick in die Potenziale und die praktischen Einsatzmöglichkeiten von KI. Dabei werden übergreifende Themen wie Zuverlässigkeit, Erklärbarkeit (xAI), cloudbasierte Plattformen, Technologien und Einführungsstrategien diskutiert. Zudem werden einzelne Anwendungsbereiche in der Wissensarbeit, Bauwirtschaft, Produktion und dem Kundenservice im Detail beleuchtet.



In der vorliegenden Studie »Feinfühlige Technik« zeigen wir anhand von praktischen Beispielszenarien und Zukunftsvisionen, welches Potenzial und welcher Mehrwert sich durch den Einsatz von neuroergonomischen Methoden und Brain-Computer-Interface-Technologien zur Lösung aktueller Probleme in der Entwicklung von Produkten oder adaptiven und autonomen Assistenzsystemen für die Arbeit, das Lernen und die Mobilität ergeben.

Wir wünschen Ihnen eine spannende Lektüre, und freuen uns, wenn wir in Zukunft auch Sie mit unserer Expertise auf Ihrem Weg zur menschenzentrierten KI unterstützen dürfen.

Wilhelm Bauer, Oliver Riedel, Thomas Renner, Matthias Peissner
Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO

INHALT

1	Management Summary	8
2	Feinfühlige Technik – eine »Annäherung« von Mensch und Technik?	10
2.1	Was ist eine feinfühlige Technik?	11
2.2	Begriffsdefinitionen	13
2.2.1	Mensch-Technik-Interaktion, User Experience und Neuroergonomie	13
2.2.2	Erkennungstechnologien zur Erfassung mentaler Prozesse	15
2.2.3	Technische Grundlagen einer feinfühligem Technik	25
2.2.4	Brain-Computer-Interfaces und neuro-adaptive Systeme	35
3	Einsatz in der Praxis	44
3.1	Einsatz von feinfühligem Technik zur Gestaltung von menschenzentrierter Technik	44
3.1.1	Optimierung der 25sten Stunde	45
3.1.2	Affective Computing – Emotionserkennung während der Interaktion	47
3.2	Feinfühlige Technik für Echtzeitanwendungen	50
3.2.1	Physiologisches Monitoring für die Fahrerzustandserkennung	50
3.2.2	Neuro-adaptive Lernassistenten und -programme	53
3.2.3	MindTrain – Förderung mentaler Fitness	55
3.2.4	Feinfühlige kollaborative Roboter	56
3.3	Qualitative Interviews	58
3.3.1	Identifizierte Potenziale feinfühligem Technik	69
4	Fazit	71

Literatur	73
KI-Fortschrittszentrum	86
Fraunhofer-Gesellschaft	87
Ansprechpersonen	89

ABBILDUNGEN

Abbildung 1: Übersicht über die Merkmale und Anwendungsbereiche gängigster Erkennungstechnologien.	15
Abbildung 2: Ablauf eines typischen Maschinellen Lernverfahrens, bestehend aus der Aufarbeitung des Datensatzes, der Trainings- und Testphase.	26
Abbildung 3: Visualisierung der Unterschiede bei überwachtem und unüberwachtem Lernen. Während im Falle des überwachten Lernens Annotationen für die Daten vorliegen, lernt ein unüberwachter Lernalgorithmus eigenständig Muster und Zusammenhänge in den Daten, die danach mit Domänenwissen zu interpretieren sind.	27
Abbildung 4: Überblick über Maschinelles Lernen, unterteilt in überwachtes und unüberwachtes Lernen, sowie die dazugehörigen Verfahren des Maschinellen Lernens (Klassifizierung, Regression, Clustering, Dimensionsreduktion).	27
Abbildung 5: Illustratives Beispiel der Standard-Pipeline anhand des EEGs. Die multivariaten Zeitreihen des EEGs enthalten in ihrem ursprünglich gemessenen Zustand Signal-Drifts, elektromagnetisches Rauschen und weitere unspezifische Artefakte, die mit den eigentlichen zu interessierenden neuronalen Signalen nichts zu tun haben. Diese Artefakte werden im Schritt der Vorverarbeitung entfernt. Nach der Vorverarbeitung werden aussagekräftige Merkmale aus den bereinigten EEG-Daten extrahiert. Danach werden die Informationen zur automatischen Dekodierung (Klassifikation oder Regression) des EEGs genutzt. Der häufigste Ansatz dabei ist das überwachte Lernen.	31
Abbildung 6: Statistik über Deep-Learning-Techniken, angewendet auf EEG-Daten. Anzahl der Publikationen pro Anwendungsbereich pro Jahr (links) und Art der verwendeten Architekturen (rechts).	32

Abbildung 7: Traditionelles Maschinelles Lernen (oben) verwendet »vordefinierte« Merkmale (Merkmal-Engineering), deren Entwicklung mühsam und kostspielig sein kann. Deep Learning (unten) lernt hierarchische Repräsentationen aus den Daten selbst und skaliert mit mehr Daten. Beim einem Deep-Learning-Netzwerk werden Merkmalsextraktion und Klassifikation in einem Schritt durchgeführt.	33
Abbildung 8: Verschiedene Arten, Hirnsignale invasiv und nicht-invasiv über ein Brain-Computer-Interface (BCI) zu erfassen. EEG (Elektroenzephalographische) Signale werden von der Kopfhaut, ECoG (Elektrocorticographie) von der Gehirnoberfläche und LFPs (Local-field Potentials) und neurale Aktionspotenziale (Spikes) von hirndurchdringenden Elektroden aufgezeichnet.	35
Abbildung 9: Definition der drei verschiedenen Typen von Brain-Computer Interfaces (BCI), aktiv, implizit und hybrid und deren jeweiliges Ziel für die Mensch-Technik-Interaktion (farbliche Zuordnung der Typen zu den Interaktionszielen; für detaillierte Beschreibungen siehe den nachfolgenden Text).	36
Abbildung 10: Der Unterschied zum klassischen Brain-Computer-Interface-Loop ist, dass hier noch ein Nutzermodell und Kontextmodell integriert ist.	39
Abbildung 11: Auswahl von psychologischen Konstrukten und Faktoren, die die Bewertung eines Produkts oder eines Services beeinflussen. Dabei werden Nutzer*innen im Sinne eines menschenzentrierten Ansatzes für die Entwicklung von feinfühligere Technik in den Mittelpunkt gestellt.	42
Abbildung 12: Aufbau des stationären Fahrsimulators (© Audi AG).	44

Abbildung 13: Die Abbildung zeigt die drei unterschiedlich getesteten Innenraumkonfigurationen. Links: Beleuchtungskonzept für die freizeitorientierte Konfiguration des prototypischen selbstfahrenden Autos – lineares, dunkleres Licht mit wenig Blauanteilen (© Audi AG). Mitte: Die normale Konfiguration basiert auf der aktuellen Erfahrung einer Autofahrt ohne spezifische Beleuchtung, mit monotonem Verkehrslärm aus der Umgebung und wenigen visuellen Ablenkungen, die auf den interaktiven Fenstern angezeigt werden (© Audi AG). Rechts: Konzentrationsfokussierte Innenraumkonfiguration des selbstfahrenden Auto-Prototyps – großflächiges, helles Licht mit hohen Blauanteilen und unscharfen Fenster-scheiben (© Audi AG).

45

Abbildung 14: In einem multimodalen neurowissenschaftlichen Ansatz wurden die Emotionen von Nutzer*innen während der Interaktion mit einem alltäglichen Elektronikgerät (hier einem Smartphone) untersucht. Dafür wurden EEG, EKG, EDA und Gesichtsemotionserkennung für die emotionale Evaluations-erkennung kombiniert.

48

Abbildung 15: Fahrsimulator im Vehicle Interaction Lab am Fraunhofer IAO. Das Fahrzeug-Mock-Up besteht aus einem Porsche Macan und wird mit der SILAB-Fahrsimulator-Software betrieben.

50

Abbildung 16: Illustratives Beispiel einer (neuro-)adaptiven Lernumgebung, die die kontinuierliche (neuro-)physiologische Evaluation mentaler Beanspruchungen und Lernprozesse ermöglicht, um auf dieser Basis Anpassungen und Optimierungen der präsentierten Lerninhalte zu ermöglichen.

52

Abbildung 17: A) Übersicht über die verwendeten Komponenten, u. a. EEG und VR, der Neurofeedback-Trainingsumgebung MindTrain. B) Ausschnitt aus der Spielumgebung von MindTrain, die zur Förderung von Entspannung und Konzentration eingesetzt wird.

54

Abbildung 18: Feinfühliges Mensch-Roboter-Kollaboration am Beispiel eines Medizintechnikroboters (z. B. für laparoskopische Anwendungen).

56

Abbildung 19: Antworten der acht Expert*innen auf die Frage: »Wo sehen Sie am meisten Potenzial für eine Optimierung von Technik auf Basis einer feinfühligsten Technik wie z. B. dem BCI?«. Mehrfachantworten möglich.

67

Abbildung 20: Anzahl der Antworten, welches Szenario das größte Potenzial für den Einsatz einer feinfühligsten Technik aufweist. Mehrfachantworten möglich.

67

Abbildung 21: Antworten der acht Expert*innen auf die Frage: »Wo sehen Sie noch weitere Einsatzpotenziale?«. Mehrfachantworten möglich.

68

1 MANAGEMENT SUMMARY

Im Zeitalter digital vernetzter Produkte und Technologien der Künstlichen Intelligenz nimmt die Gestaltung der Schnittstellen zwischen Mensch und Maschine eine Schlüsselrolle ein. Die Studie zeigt auf, welche neuen Perspektiven und Potenziale sich hier durch neuroergonomische Methoden für die Gestaltung von menschengerechter Technik und Arbeit ergeben. Anhand von Praxisbeispielen berichten wir, welche Methoden und Technologien sich nutzen lassen, um Technikdesign so zu optimieren, dass Produkte und Services auf die Bedürfnisse der Nutzer*innen ausgerichtet sind und Gestaltungsprozesse der Menschzentrierung und Akzeptanz angemessen berücksichtigt werden. Fragen, die durch die Neuroergonomie beantwortet werden können, sind z. B. wie hoch die kognitive Belastung oder wie das emotionale Wohlbefinden der Menschen während des Umgangs mit Technik ist. Welche Denkprozesse und Verhaltensweisen fördern ein positives Erleben im Umgang mit Technik? Wie kann eine Mensch-Technik-Interaktion möglichst umfassend evaluiert werden, um Ergebnisse für die Gestaltung von Arbeitsplätzen und Technik zu berücksichtigen?

Weiterhin zeigen wir, wie sich aktuelle Neurotechnologien einsetzen lassen, um Signale des Gehirns oder auch körperliche Erregungsmuster zu messen und somit emotionale und kognitive Zustände in Echtzeit zu erkennen – eine *feinfühlige Technik*. Dies ist mit sogenannten Brain-Computer-Interfaces (BCIs) möglich. Aktuell ist der Einsatz von BCIs noch überwiegend für medizinische Anwendungen etabliert, z. B. in technischen Systemen zur Kommunikation bei schwerst gelähmten Patient*innen. In realen Situationen der Mensch-Technik-Interaktion können sie noch nicht ohne Weiteres genutzt werden, da ihr Einsatz noch streng kontrollierte Bedingungen erfordert. Die Studie informiert darüber, wo Herausforderungen für Entwickelnde und Endnutzer*innen im Einsatz liegen. Anhand von praktischen Beispielszenarien und Zukunftsvisionen erläutern wir, welches Potenzial und welcher Mehrwert sich durch den Einsatz von neuroergonomischen Methoden und BCI-Technologien zur Lösung aktueller Probleme in der Entwicklung von Produkten oder adaptiven und autonomen Assistenzsystemen für die Arbeit, das Lernen und die Mobilität ergeben.

In Gesprächen mit Expert*innen aus der Praxis haben wir diese Potenziale diskutiert und gemeinsam anwendungsorientierte Forschungs- und Entwicklungsthemen mit besonders großem Potenzial erörtert: i) die Nutzerzustandserkennung und situationssensitive Anpassung der Maschine an einzelne Nutzer*innen mittels feinfühler Technik, ii) die Förderung positiver Emotionen und kognitiver Faktoren wie Aufmerksamkeit, Konzentration und Kontrollfähigkeit in oder mithilfe der Interaktion mit feinfühler Technik, iii) das interaktive Eintrainieren von Maschinenverhalten (u. a. auch Roboter) mittels BCI-basiertem verstärkendem Lernen (Reinforcement Learning).

2 FEINFÜHLIGE TECHNIK – EINE »ANNÄHERUNG« VON MENSCH UND TECHNIK?

Heutzutage ist ein Alltag ohne die Hilfe von technischen Systemen kaum mehr vorstellbar. Historisch betrachtet ist der Einsatz und die Entwicklung von Werkzeugen, zu denen auch technologische Entwicklungen gehören, stark mit der Evolution und Intelligenz des Menschen verbunden. So haben sich Technologien – und wie Menschen damit umgehen, leben und denken – enorm verändert. Immer häufiger begegnen wir interaktiven Systemen, die in gewissem Rahmen eigenständig und eigendynamisch handeln und Entscheidungen treffen. So können wir bereits mit manchen Robotern reden, wohingegen andere auf unsere Gesten reagieren. Smartphones sind zu täglichen Begleitern geworden. Gesichter können automatisch auf Fotos erkannt werden. Wir haben Autos, die selbst einparken, und das Fliegen ist fast vollständig automatisiert.

Mobile und ubiquitäre Sensortechnologien, die fortschreitende Digitalisierung sowie Technologien der künstlichen Intelligenz (KI) leisten dazu einen enormen Beitrag und können als *Enabler-Technologien* auf dem Weg zu einer immer »feinfühligere[n] Technik« angesehen werden. Durch sie werden neue Technologieinnovationen vorangetrieben, wodurch sich Tätigkeiten und Prozesse zunehmend automatisieren lassen. Somit kann die Produktivität und Effizienz gesteigert werden, was zusätzlich auch Zeitersparnisse für die Menschen mit sich bringt. Jedoch birgt die verstärkte technische Integration in die bestehende Arbeitswelt auch neue Herausforderungen und Konfliktpotenziale. Oftmals findet ein Mensch mit seinen individuellen Präferenzen und Bedürfnissen bei der Entwicklung technischer Systeme wenig Berücksichtigung. Daraus können Lösungen resultieren, die technisch zwar fortschrittlich sind, jedoch kaum nennenswerte positive Effekte auf Produktivität, Kreativität und Gesundheit der beteiligten Nutzer*innen erzielen können [1]. Die Herausforderung dieser zunehmenden Technologisierung ist es, geeignete Arbeitsumgebungen zu schaffen, die den Menschen die bestmögliche Unterstützung zur Erledigung ihrer Tätigkeiten in verschiedensten Situationen geben.

Doch der Wert der Technik liegt nicht in erster Linie darin, dass sie menschliche Arbeit übernehmen kann. Die Arbeit der Zukunft wird entscheidend durch eine enge Kooperation mit Technik geprägt sein [2]. Wenn das geschieht, können neue Möglichkeiten optimal ausgeschöpft werden. Mensch und Technik organisieren sich in sozio-technischen Systemen. Gemeinsam lösen sie Probleme und treffen fundierte Entscheidungen. So können sich Mensch und Technik gegenseitig ergänzen und müssen nicht in Konkurrenz zueinander stehen. Für ein Miteinander auf Augenhöhe muss die Technik jedoch intuitiv zu bedienen sein und sich intelligent an ihre Nutzer*innen anpassen können. So muss sie die Nutzer*innen wahrnehmen und auf diese reagieren können. Neben einem gegenseitigen »Verständnis« zwischen Mensch und Technik werden dadurch insbesondere die Motivation und das Wohlbefinden der Mitarbeiter*innen gefördert [2]–[4]. Obwohl die Vorteile unbestreitbar sind, muss eine immer intelligenter werdende Technik so gestaltet sein, dass sie trotz ihrer Dynamik allgemein nachvollziehbar und gesellschaftlich akzeptierbar ist. Die Erfolgsgrundlage eines partnerschaftlichen Verhältnisses zwischen Mensch und Technik ist eine »feinfühlige Technik«.

2.1 Was ist eine feinfühlige Technik?

In einer zunehmend technologisierten Arbeitswelt sind wissenschaftliche Erkenntnisse, die zum Verständnis und zur Verbesserung der Interaktion zwischen Mensch und Technik beitragen und damit eine effiziente Nutzung technischer Produkte durch die Menschen ermöglichen, von zentraler Bedeutung. In diesem Zuge gewinnt das Forschungsfeld der Mensch-Technik-Interaktion (MTI) immer mehr an Bedeutung. Technologische Fortschritte verändern nicht nur allmählich die Art und Weise, wie mit Technologien interagiert wird, sondern beeinflussen auch die sensorischen Fertigkeiten und kognitiven Fähigkeiten auf unterschiedliche Weise [1]. In einer kürzlich veröffentlichten wissenschaftlichen Übersichtsstudie fassen Osiurak und Kolleg*innen [5] diese technologischen Entwicklungen in drei Ebenen zusammen, die die Interaktion zwischen Mensch und Technik als *physische* (engl. *affordance design*), *fortgeschrittene* (engl. *automation and interface design*) und *symbiotische* (engl. *embodied und cognitive design*) Technologien beschreiben. In diesem Zusammenhang deuten zukünftige Trends wie sprach-, gesten- oder gar gedankengesteuerte Technologien auf eine zunehmende Symbiose von Mensch und Technik hin [1]. So forschen Neurowissenschaftler*innen und KI-Forscher*innen an der automatischen Erkennung von kognitiven und emotionalen Prozessen, um diese zur Verbesserung der Technik nutzen zu können und so einen neuen Meilenstein in der Interaktion zwischen Mensch und Technik zu schaffen. Doch wie kann eine symbiotische Interaktion mit einer Maschine oder gar einer feinfühiligen Technik aussehen?

Während wir bei einer Mensch-zu-Mensch-Interaktion sofort erkennen und darauf empathisch reagieren können, wenn unser Gegenüber Schwierigkeiten hat zu folgen oder mit der Art der Zusammenarbeit unzufrieden ist, ist dies bei einer Maschine nicht der Fall. Generell unterscheidet man zwischen der Fähigkeit, die Perspektive einer anderen Person zu verstehen, d. h. *kognitive Empathie*, und der Fähigkeit zu fühlen, was die andere Person fühlt, d. h. *affektive oder emotionale Empathie* [6], [7]. Diese Differenzierung ist aus der Perspektive des technischen Systemdesigns sehr wichtig. Denn beim derzeitigen Stand der KI-Forschung erscheint es unwahrscheinlich, dass technische Systeme bald zu affektiver Empathie fähig sein werden. Technische Systeme benötigen kein affektives Einfühlungsvermögen, um für Menschen hilfreich zu sein. Das kognitive Einfühlungsvermögen, also die Fähigkeit, einen Menschen zu verstehen, kann Systeme bereits in die Lage versetzen, Nutzer*innen eine maßgeschneiderte, situationsspezifische Unterstützung zu bieten [8]. Technische Systeme benötigen nicht einmal Einfühlungsvermögen im Sinne eines vollständigen Verständnisses des emotionalen oder gar kognitiven Spektrums der Nutzer*innen. Aber in einigen Fällen kann es hilfreich sein, wenn eine begrenzte Anzahl von Zuständen eines Nutzers oder einer Nutzerin verstanden werden. Basierend auf diesen Überlegungen konzeptualisieren wir eine »feinfühlige Technik« wie folgt (in Anlehnung an [8]):

»Technische Systeme, die in der Lage sind, einen interessierenden Benutzerzustand zu erkennen und Interaktionsstrategien zu lernen, um auf diesen Benutzerzustand maßgeschneidert zu reagieren«.

Feinfühlige Systeme können somit Emotionen oder kognitive Prozesse, wie Aufmerksamkeit oder die mentale Belastung, von einzelnen Nutzer*innen erfassen und darauf basierend adäquate Systemreaktionen initiieren. Dies schafft neue Interaktionsmöglichkeiten im Sinne des *symbiotischen Designs* [5]. Grundsätzlich können Technologien zur Zustandserkennung nicht nur zu Interaktionszwecken eingesetzt werden, sondern auch, um Rückschlüsse auf die physische und kognitive Beanspruchung, Produktwirkung, Akzeptanz und das Allgemeinbefinden zu ziehen. Diese Kenntnisse sind ein zentraler Baustein für eine menschenzentrierte Entwicklung neuer Technologien und die Verbesserung von Arbeitsabläufen. Im Folgenden werden einige grundlegende Begriffe im Zusammenhang mit feinfühlgiger Technik eingeführt.

2.2 Begriffsdefinitionen

2.2.1 Mensch-Technik-Interaktion, User Experience und Neuroergonomie

Durch neue digitale Technologien und KI erhöht sich das Maß an Informationen, die ein Mensch verarbeiten muss. Erkenntnisse aus der Kognitionsforschung zeigen, dass die Anzahl der Informationen, die wir verarbeiten können, begrenzt ist. Die genaue Anzahl ist von

Individuum zu Individuum verschieden [9]. Als Folge der ansteigenden Komplexität und Menge an Information treten kognitive Prozesse wie die Arbeitsgedächtnisleistung und Informationsverarbeitung sowie die psychische Beanspruchung zunehmend in den Vordergrund der Betrachtungen. Neben kognitiven Prozessen spielen Fragen der Gestaltung und Evaluation von Arbeitssituationen und deren Anpassung an die Bedürfnisse und Fähigkeiten von Menschen eine immer wichtigere Rolle in der Arbeitswissenschaft. Eine gute Gebrauchstauglichkeit und positive User Experience (UX) sind Schlüsselfaktoren für den Erfolg von technischen Systemen, Produkten, Services und Arbeitsabläufen [3], [10]. In der Entwicklung spielen daher mentale Aspekte der UX (Nutzerzustände) eine wichtige Rolle. Dabei stellen sich folgende Fragen: Wie hoch ist die kognitive Belastung während der Arbeitstätigkeit? Wie ist das emotionale Erlebnis eines Menschen während der Interaktion mit Technik? Um diese Fragen hinreichend beantworten zu können, bedarf es neben psychologischen auch neurowissenschaftlicher Methoden zur Messung mentaler Faktoren der UX. Die Weiterentwicklung und der praxistaugliche Transfer dieser Methoden ist für Unternehmen von größter Bedeutung, um Produktentwicklung, Prozessführung und Arbeitsschritte im Hinblick auf ein positives Erlebnis zu verbessern und menschengerecht zu gestalten [3], [4], [11].

In der Vergangenheit wurden Fragestellungen zur kognitiven Belastung und dem emotionalen Erleben in der MTI-Forschung hauptsächlich mittels verhaltensbasierter Maße, wie bspw. Fehleraten und Reaktionsgeschwindigkeiten, und subjektiver Verfahren, wie Fragebögen und Interviews, erfasst. Allerdings ist der Einsatz dieser Methoden mit einigen Einschränkungen verbunden: Während neurophysiologische Methoden es erlauben, direkte Korrelate oder auch Vorboten der kognitiven Unter- oder Überforderung zu untersuchen, zeichnet sich Unter- oder Überforderung in verhaltensbasierten Maßen nur indirekt als Folge ab. Interaktionen verschiedener kognitiver Prozesse – z. B. Frustration und Überforderung – lassen sich mittels verhaltensbasierter Maße nur eingeschränkt untersuchen. Fragebögen beschränken sich auf subjektive Aussagen, welche die Fähigkeit zur Introspektion und Metareflexion erfordern. Implizite affektive Evaluationen können mittels subjektiver Methoden nur schwer erfasst werden [12], [13]. Darüber hinaus erlauben subjektive Methoden keine unmittelbare Messung des Erlebnisses, denn sie werden nach der Techniknutzung eingesetzt. Zwischen dem Erlebnis und der Messung sind kognitive Bewertungsprozesse, die zu Verzerrungen und Attributionsfehlern (Zuschreibung bestimmter Eigenschaften) führen können, sowie Selektionsprozesse (z. B. aufgrund sprachlicher Einschränkungen das Erleben zu beschreiben; [14], [15]) geschaltet. Dementsprechend können Veränderungen des Erlebens direkt während der Techniknutzung nicht erfasst werden [16]. Vor diesem Hintergrund ist die Ergänzung durch neurowissenschaftliche Methoden, die den Zugriff auf die *implizit* mentalen Zustände von Nutzer*innen ermöglichen, zur Erfassung und Bewertung des Erlebens relevant.

FEINFÜHLIGE TECHNIK – EINE »ANNÄHERUNG« VON MENSCH UND TECHNIK?

In diesem Zuge ist die *Neuroergonomie* eine aufstrebende neue Forschungsdisziplin mit großem Potenzial für Wissenschaft und Praxis. Das Forschungsfeld der Neuroergonomie liegt an der Schnittstelle zwischen Psychologie, kognitiver Neurowissenschaft, Arbeitswissenschaft und künstlicher Intelligenz.

Dabei verfolgt die Neuroergonomie zwei Ziele:

1. ein besseres Verständnis von der menschlichen Leistungsfähigkeit und den zugrundeliegenden Gehirnfunktionen zu erhalten und
2. das körperliche und mentale Wohlbefinden bei der Arbeit und im Alltag zu fördern.

Die Neuroergonomie ist dabei motiviert, Methoden und Theorien aus den unterschiedlichen Forschungsdisziplinen effektiv anzuwenden, um zu verstehen, wie das Gehirn im Alltag funktioniert. So sollen zum Beispiel Kenntnisse über die Arbeitsweise des menschlichen Gehirns genutzt werden, um sichere und komfortable Schnittstellen zu technischen Systemen zu entwickeln. Das Spektrum der neuroergonomischen Forschung umfasst die psychologisch-neurowissenschaftliche Erforschung menschlicher Wahrnehmung und Informationsverarbeitung, der Entscheidungsfindung und des emotionalen Erlebens. Die Erkenntnisse finden Anwendung in der Gestaltung von Arbeitsplätzen und Entwicklung komfortabler und Akzeptanz förderlicher Mensch-Maschine-Schnittstellen in realen Anwendungsszenarien. Anwendungsgebiete sind z. B. die Luftfahrt, das (teil-) automatisierte Fahren oder die Interaktion von Menschen mit Computern sowie weitere autonome und adaptive Maschinen oder Robotern. So lassen sich konkret Herausforderungen und Fragestellungen einer menschenzentrierten Technikentwicklung und Arbeitsplatzgestaltung angehen, wie z. B.:

- Welche Faktoren beeinflussen die Leistungsfähigkeit von Menschen in modernen digitalisierten Arbeitsumgebungen?
- Wie hoch ist die kognitive Belastung während der Arbeitstätigkeit?
- Welche Rolle spielen Emotionen bei der Mensch-Technik-Interaktion und wie hängen sie mit kognitiven Prozessen zusammen?
- Welche Denkprozesse und Verhaltensweisen fördern ein positives Erleben im Umgang mit Technik?
- Wie kann eine Mensch-Technik-Interaktion möglichst umfassend evaluiert werden?
- Welche Eigenschaften müssen Schnittstellen zwischen Mensch und Technik aufweisen, damit die Nutzer*innen besser mit Informationen umgehen können – also besser lernen oder bessere Entscheidungen fällen?
- Wie können neuroergonomische Ergebnisse der praxisnahen Forschung bei der Gestaltung realer Arbeitsplätze berücksichtigt werden?

Neuroergonomie

Fortschritte neurowissenschaftlicher Messtechnologien erlauben es uns zunehmend, einfach handhabbare Messungen durchzuführen (siehe auch Abschnitt 2.2.2 für nähere Erläuterungen). Dies ermöglicht ein besseres Verständnis davon, wie Körper und Gehirn verschiedene Aktivitäten in unserem alltäglichen Leben ausführen – vom Gehen über das Steuern eines Flugzeugs bis hin zur Navigation auf einem virtuellen Computer-Desktop. Dies gewährt uns einen Einblick, wie sich unsere natürlichen Reaktionen auf wahrgenommene Reize auswirken können. Die Neuroergonomie bezieht sich darauf, wie neurowissenschaftliche Methoden eingesetzt werden können, um die zugrundeliegenden psychologischen Prozesse während alltäglicher Aktivitäten zu verstehen. Ergänzend zu Leistungsmaßen und subjektiven Einstellungen erlauben uns neurowissenschaftliche Methoden, Faktoren zu berücksichtigen, die der Arbeitstätigkeit direkt zugrunde liegen, wie zum Beispiel: Aufgabenengagement, kognitive Arbeitsbelastung, Frustration, wahrgenommene Valenz und weitere. Das weitreichende Ziel der Neuroergonomie ist es, sich auf valide Messungen mentaler Zustände zu stützen, um Arbeitsplätze und Lebensräume zu schaffen, die auf unsere individuellen Bedürfnisse, Fähigkeiten und Präferenzen abgestimmt sind. Dies wird immer wichtiger, da in Zukunft die Art und Weise unserer Arbeitstätigkeit und -plätze durch kognitive statt physischer Arbeit neu definiert wird. Fabrikarbeiter*innen müssen mit Robotern zusammenarbeiten, Pilot*innen überwachen größtenteils automatisierte Flüge und (halb-)automatische Fahrzeuge verlangen von ihren Nutzer*innen, dass sie effektiv zwischen Freizeitaktivitäten und Fahren wechseln können.



2.2.2 Erkennungstechnologien zur Erfassung mentaler Prozesse

Zentraler Bestandteil einer feinfühligsten Technik sind Erkennungstechnologien wie mobil einsetzbare, neurophysiologische und kamera- oder sensorbasierte Verfahren, um anhand der gemessenen Signale Rückschlüsse auf die Aufmerksamkeit, Affekt, Frustration, kognitive Belastung, Produktwirkung, Akzeptanz, aber auch das Allgemeinbefinden eines Nutzers oder einer Nutzerin zu schließen. Dies ermöglicht der neuroergonomischen Forschung eine objektive und wissenschaftlich fundierte Evaluation, die für die Verbesserung von Produkten, Services und Arbeitsabläufen verwendet werden kann. So lassen sich diese Verfahren bereits heute in zahlreichen Anwendungsfeldern einsetzen, dies sind u. a.:

- User Experience Testing – z. B. von Sprachdialogsystemen und User Interfaces,
- Produktwirkung – z. B. von Lebensmitteln und Konsumgütern,

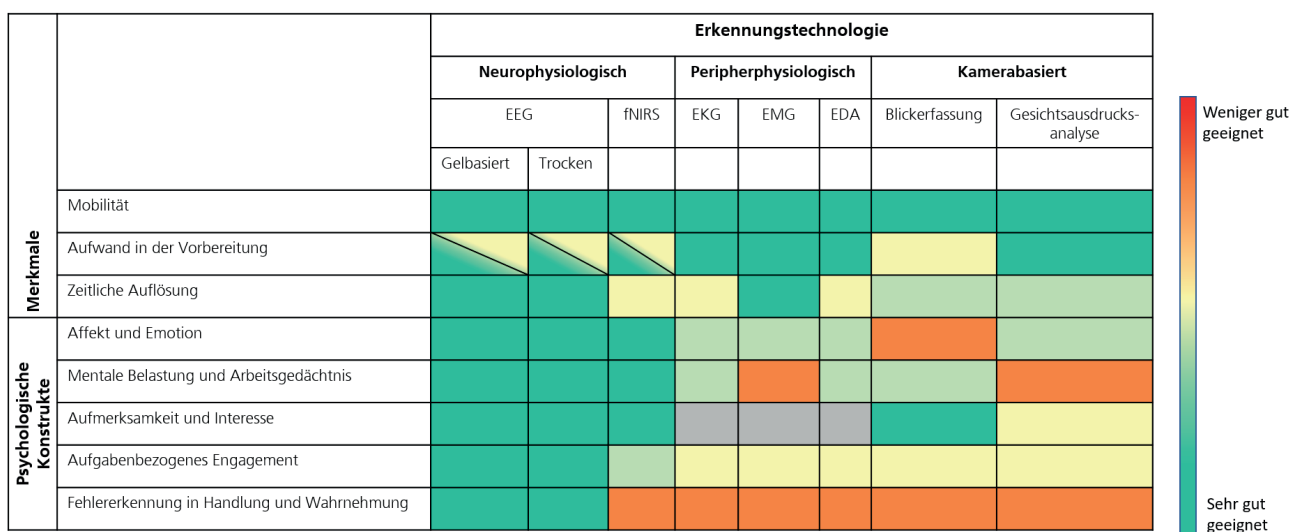
- Gesundheit – z. B. Gemütszustände bei Patient*innen oder auch Depressivität,
- Arbeitsbelastung – z. B. Operateure von sicherheitskritischen Infrastrukturen,
- Serviceevaluation – z. B. von digitalen Dienstleistungen,
- Mensch-Technik-Interaktion im Allgemeinen – z. B. Fahrerzustandserkennung und Kollaboration mit Robotern.

Im Nachfolgenden wird die Hardware solcher Erkennungstechnologien genauer beschrieben, um zu erläutern, welcher Sensor sich am besten für die Messung bestimmter psychologischer Konstrukte eignet. Abbildung 1 gibt eine Übersicht über die wichtigsten Merkmale, praktischen Anwendungsbereiche, sowie Vor- und Nachteile der im Folgenden vorgestellten Erkennungstechnologien.

2.2.2.1 Neurophysiologische Messmethoden

Elektroenzephalographie (EEG)

Die Elektroenzephalographie (EEG) ermöglicht, die Hirnaktivität einzelner Nutzer*innen direkt über elektrophysiologische Signale zu messen. Dazu werden Elektroden auf der Kopfhaut angebracht, um dann Spannungsschwankungen aufzuzeichnen. Diese Spannungsänderungen des elektrischen Zustands werden durch physiologische Prozesse einer Population von synchron aktiven Neuronen während ihrer Informationsverarbeitung verursacht. Hierbei ist zu beachten, dass bei der EEG die Summe der Schwankungen aller Neurone in der Nähe der jeweiligen Elektrode gemessen wird und die Potenzialänderungen einzelner Neurone nicht erfasst werden können. Die aufgezeichneten EEG-Kurven werden mittels der Größen *Amplitude* (1–200 μV) und *Frequenz* (0.5– ca. 40 Hz) beschrieben. Dabei werden verschiedene Frequenzbereiche unterschieden, die mit verschiedenen Aufmerksamkeitszuständen, Reizverarbeitungsabläufen und kognitiven Funktionen assoziiert sind. Einerseits erlaubt die EEG die Betrachtung von oszillatorischer Aktivität, sogenannter Spontanaktivität, im Frequenzbereich. Andererseits ist es möglich, Potenzialschwankungen, sogenannte evozierte Aktivität, die mit einem bestimmten Ereignis oder Reiz verbunden ist, zu untersuchen. Mithilfe der EEG ist es also möglich, die Veränderungen in der Hirnaktivität zu erkennen.



Für die EEG-Messung können hauptsächlich zwei Typen von Hardware Sensoren unterschieden werden: Standardgemäß wird in den meisten Studien ein sogenanntes gelbasiertes EEG verwendet, bei dem zwischen einzelne Elektroden und Kopfhaut ein Gel eingespritzt wird, das die Leitungsfähigkeit erhöht und somit für ein besseres Signal sorgt. Gelbasierte EEGs wurden lange Zeit, aufgrund des kabelgebundenen Set-ups, vor allem bei stationären Messungen angewandt. Das sind stets Messungen, bei denen sich die Nutzer*innen nicht großartig bewegen müssen. Inzwischen gibt es jedoch auch kabellose gelbasierte EEG-Geräte, die erlauben, die Hirnaktivität möglichst unter realen Bedingungen oder bei körperlicher Aktivität zu messen. In diesem Fall werden die gemessenen Informationen kabellos über Bluetooth (oder auch Wi-Fi-Signal) an einen PC übertragen. Soll die Vorbereitungszeit verkürzt werden, bietet sich ein Trocken-EEG an, bei dem kein Gel zwischen Elektrode und Kopfhaut verwendet werden muss. Diese können ebenfalls stationär oder mobil angewandt werden. Dieses System vermeidet jedoch keine Bewegungsartefakte. Der Vorteil eines Trocken-EEGs liegt ausschließlich in der einfacheren Handhabung und geringen Vorbereitungszeit.

Abbildung 1: Übersicht über die Merkmale und Anwendungsgebiete gängigster Erkennungstechnologien.

Zusammenfassend lässt sich sagen, dass das EEG aufgrund seiner Eigenschaft, elektrophysiologische Signale zu messen, eine gute zeitliche Auflösung bietet, d. h. es lässt sich einfach ermitteln, wann eine Änderung in der Hirnaktivität stattfindet. Jedoch lässt sich nur schwer ermitteln, wo diese Änderung im Gehirn stattgefunden hat, da die genaue Lokalisierung der aktiven Hirnareale vom EEG nur bedingt erfasst werden kann. Das bedeutet, es weist eine schlechte räumliche Auflösung auf.

Funktionelle Nahinfrarotspektroskopie (fNIRS)

Hirnaktivität kann aber nicht nur durch ihre elektrophysiologischen Eigenschaften gemessen werden. Erhöhte neuronale Aktivität, z. B. ausgelöst durch die Ausführung einer bestimmten Aufgabe, führt außerdem dazu, dass in den Regionen der aktiven Neurone mehr Sauerstoff benötigt wird. Diese hämodynamischen Eigenschaften, die die Unterschiede im Sauerstoffgehalt des Blutes beschreiben, können indirekt über ein optisches Verfahren, die *funktionelle Nahinfrarotspektroskopie (fNIRS)*, gemessen werden [17]. Dabei misst ein Detektor, wie viel Licht einer Nahinfrarotlichtquelle das Hirngewebe durchdrungen hat. Genauer gesagt, wie viel Licht von Hämoglobin, dem roten Blutfarbstoff, absorbiert wurde. Dies ist abhängig vom Sauerstoffgehalt im Blut. Eine erhöhte neuronale Aktivität bedeutet eine erhöhte Menge an Sauerstoff im Blut, was zu einer geringeren Absorptionsrate führt. Das bedeutet, dass mehr Licht wieder zurückgeworfen und vom Detektor gemessen wird. Durch die Detektion der Menge an absorbiertem Nahinfrarotlicht werden Rückschlüsse auf die Aktivität im Gehirn möglich. Da bei der fNIRS lichtbasiert Gehirnaktivität gemessen werden kann, ist es weniger störanfällig gegenüber Elektrorauschen und Bewegungsartefakten.

Des Weiteren weist dieses Verfahren im Vergleich zum bereits beschriebenen EEG-System eine gute räumliche Auflösung auf, d. h. es beschreibt auch, wo im Gehirn erhöhte Aktivität stattfindet. Da mittels der fNIRS der Sauerstoffgehalt im Blut gemessen wird, ist jedoch immer eine gewisse zeitliche Latenz im gemessenen Signal vorhanden. Dies ist darauf zurückzuführen, dass es einige Sekunden dauert, bis der benötigte Sauerstoff an den jeweiligen Neuronen eingetroffen ist. Diese zeitliche Latenz erschwert es, den genauen Zeitpunkt der Änderung in der Hirnaktivität zu messen; somit weist die fNIRS eine schlechte zeitliche Auflösung auf.

Die Wahl zwischen EEG und fNIRS sollte also abhängig davon getroffen werden, ob der Zeitpunkt der Änderung in der Hirnaktivität wichtig ist, oder ob die Lokalisation aktiver Hirnareale im Vordergrund stehen soll.

2.2.2.2 Peripher-physiologische Messmethoden

Elektrokardiographie (EKG)

Mithilfe einer Elektrokardiographie (EKG) lassen sich nicht nur Aussagen zur medizinischen Gesundheit des Herzens treffen, es gibt auch Aufschlüsse über aktuelle kognitive und affektive Zustände der Person. So lassen sich z. B. Zustände wie Anstrengung, Stress oder Nervosität anhand einer gesteigerten Herzaktivität messen.

Bei der Elektrokardiographie werden elektrische Spannungsänderungen des Herzens gemessen und aufgezeichnet. Diese Spannungsänderungen entstehen durch die Kontraktion des Herzmuskels, genauer gesagt der Herzmuskelzellen. Dieses Verfahren benötigt zwei Elektroden, die

oberflächlich auf der Haut angebracht werden und zwischen denen die Spannungsänderung gemessen wird, sowie eine Referenzelektrode. Es stellt daher ein nicht-invasives Verfahren mit geringem Vorbereitungsaufwand dar. EKG-Verfahren sind sowohl in der Medizin und der Forschung als auch im Consumerbereich bereits sehr etabliert.

Elektromyographie (EMG)

Ähnlich wie bei der Elektrokardiographie werden bei der Elektromyographie (EMG) elektrische Spannungsänderungen zwischen Muskeln gemessen und aufgezeichnet. Diese Spannungsänderungen können entweder von einem ruhenden Muskel oder von einem kontrahierten Muskel gemessen werden. Dafür werden oberflächlich Elektroden auf der Haut angebracht, die dann das Summenpotenzial eines ganzen Muskels messen. Dies hat jedoch den Nachteil, dass das gemessene Signal unpräzise und störanfällig ist. Es können also keine Signale einzelner Muskelfasern gemessen werden.

Elektrodermale Aktivität (EDA)

Durch Messung der elektrodermalen Aktivität (EDA) ist es möglich, die Hautleitfähigkeit eines Menschen zu bestimmen. Diese Leitfähigkeit kann durch kurzzeitige emotionale Reaktionen wie z.B. Angst oder Stress beeinflusst werden. Wird durch solch eine emotionale Reaktion vermehrt Schweiß auf der Haut produziert, führt dies zu einer Verringerung des elektrischen Leitungswiderstands und somit zu einer erhöhten Hautleitfähigkeit. Diese Hautleitfähigkeit wird durch zwei Elektroden gemessen, die an der Hautoberfläche von Zeige- und Mittelfinger der Person angebracht werden. Bei der EDA handelt es sich um ein komplett nicht invasives, einfach anzuwendendes Verfahren, mit dessen Hilfe es möglich ist, vor allem unbewusste objektive Reaktionen zu bestimmen [18]. Aufgrund der kabellosen Übertragung der gemessenen Daten per Bluetooth an einen PC kann eine EDA-Messung unter realen Bedingungen ohne großen Aufwand stattfinden.

2.2.2.3 Kamerabasierte Messmethoden

Blickerfassung

Mithilfe sogenannter Eyetracking-Systeme ist es möglich, verschiedenste Arten von Blickbewegungen aufzuzeichnen und zu analysieren. Dabei wird hauptsächlich zwischen zwei Arten von Augenbewegungen unterschieden: Fixationen und Sakkaden. Während einer Fixation werden Informationen bewusst wahrgenommen und verarbeitet. Die Fixationsdauer oder die Anzahl an Fixationen innerhalb eines bestimmten Bereichs gibt unter anderem Aufschluss über die Komplexität oder Wichtigkeit der zu betrachtenden Information. Im Gegensatz dazu beschreiben Sakkaden die Bewegung von einer Fixation zur nächsten und geben keinen direkten Aufschluss über die Komplexität einer Information, da während dieser schnellen Augenbewegungen keine

Informationsverarbeitung im Gehirn stattfindet. Sie dienen der Suche nach visuellen Reizen bzw. der Orientierung und geben daher nur indirekt (über ihre Länge) Hinweise auf die Schwierigkeit oder Komplexität einer Information.

Des Weiteren werden beim Eyetracking Merkmale wie die Größe der Pupille (Pupillendilatation) oder die Häufigkeit des Blinzeln aufgezeichnet. Ersteres gibt einen Hinweis auf die kognitive Auslastung bzw. die Schwierigkeit der zu bewältigenden Aufgabe (je größer die Pupille, desto höher die kognitive Auslastung).

In der Regel bestehen Eyetracking-Systeme aus einer Infrarotkamera, die an einem PC-Monitor befestigt ist. Das Infrarotlicht wird auf das Auge gerichtet, durchdringt die Retina (Netzhaut) und wird größtenteils wieder reflektiert. Diese Reflektion in Form einer hellen Scheibe (Reflektion der Pupille) bzw. eines hellen Punktes (Reflektion der Hornhaut/Cornea) wird von der Kamera aufgenommen und an eine Bildverarbeitungssoftware geleitet, die die Position des Auges berechnet. Die Position der Cornea in Relation zur Pupille gibt Aufschluss über die Blickposition der Person [19].

Gesichtsausdrucksanalyse

Die Erkennung und Identifizierung von menschlichen Gesichtsausdrücken wird auch als »Facial Decoding« bezeichnet. Hierbei werden durch eine Kamera die Gesichtszüge der Nutzer*innen aufgezeichnet und diese werden dann mittels spezieller Software, z. B. SHORE¹, oder AFFDEX [20] analysiert. Die erkannten Gesichtsmuskelaktivierungen werden in Kategorien typischer emotionaler Zustände, wie zum Beispiel die Basisemotionen Freude, Wut, Ekel, Angst, Traurigkeit und Überraschung, klassifiziert. Es wird die Wahrscheinlichkeit berechnet, inwieweit der erkannte Zustand der zugeordneten Kategorie entspricht (mehr Informationen zur Klassifikation in Kapitel 2.2.3). Dabei liegt der Fokus auf die für jeden Gesichtsausdruck notwendigen Muskeln [21].

¹ <https://www.iis.fraunhofer.de/de/fffsse/imaging-and-analysis/iis/tech/shore-facedetection.html>; aufgerufen am 12.11.2020.



Zukünftige technische Entwicklungsperspektive

Generell ist das Ziel, die Hardware der bereits beschriebenen Erkennungstechniken in der Zukunft immer weiter zu verkleinern, kabellos zu gestalten und somit mobil zu machen. Dies ermöglicht die Messung physiologischer und psychologischer Konstrukte außerhalb des Labors – unter realen Bedingungen. So erlauben mobile EEG- oder fNIRS-Geräte die Messung von Änderungen in der Hirnaktivität auch während der Bewegung der einzelnen Nutzer*innen bzw. bei Anwendung in der alltäglichen Umgebung. Des Weiteren ermöglichen moderne Geräte auch Kombinationen aus EEG und fNIRS, um sowohl die zeitliche als auch räumliche Auflösung innerhalb einer Fragestellung zeitgleich zu untersuchen.

Auch im Bereich der peripher-physiologischen Messmethoden ist es mittlerweile möglich, diese mobil anzuwenden. So gibt es EKG-Systeme, die auch auf mobilen Endgeräten (z. B. Smartphones oder Tablets) über eine spezielle App abgerufen werden können.

Im Bereich der kamerabasierten Messmethoden erfordert eine Blickerfassung inzwischen nicht mehr nur einen stationären PC mit angebrachter Kamera, sondern ist z. B. in einer Brille integriert mobil einsetzbar (u. a. Tobii Glasses²). Dies ermöglicht die Blickerfassung unter realen Bedingungen. Die Gesichtsausdrucksanalyse Software SHORE2 liefert eine Echtzeitanwendung auf mobilen Endgeräten wie Smartphones oder Google Glasses. Somit kann die Emotionsanalyse in viele alltägliche Bereiche (z. B. beim Autofahren³) integriert werden³.

Für die Entwicklung und den Einsatz einer feinfühligten Erkennungstechnologie ist die genaue Kenntnis der psychologischen Vorgänge und entsprechender (neuro-)physiologischer Korrelate (Gehirnsignale, die mit den Vorgängen einhergehen) essenziell. Im Folgenden werden für die praxisnahe Entwicklung von feinfühligten Erkennungstechnologien relevante psychologische Konstrukte, Prozesse und Verhaltensweisen beschrieben sowie deren zugrundeliegenden Hirnzustände und -aktivitäten vorgestellt.

² <https://www.tobiipro.com/de/produkte/tobii-pro-glasses-3/>; aufgerufen am 12.11.2020.

³ <https://www.iis.fraunhofer.de/de/ff/iis/imaging-and-analysis/iis/tech/shore-facedetection.html>; aufgerufen am 12.11.2020.

Affekt und Emotion

Affektive und emotionale Faktoren der Mensch-Technik-Interaktion haben in letzter Zeit stark an Bedeutung gewonnen [22], [23]. Sie werden als wichtige Voraussetzung für die Nutzerakzeptanz betrachtet und können über Motivation und Nutzerengagement die Performanz von Mensch-Technik-Systemen beeinflussen. Darüber hinaus können positive Nutzungserlebnisse auch einen Beitrag zum allgemeinen Wohlbefinden und zur Arbeitszufriedenheit leisten. Durch die Weiterentwicklung neurophysiologischer Verfahren hat die kontinuierliche Echtzeiterfassung emotionaler Reaktionen in den letzten Jahren große Fortschritte erfahren. Emotionen können parallel über die beiden Dimensionen Valenz (positiv, neutral, negativ) und Arousal (Grad der Aktivierung: von ruhig bis erregt) erfasst werden. Für die Valenzmessung wird die Elektroenzephalographie (EEG) und ergänzend die funktionelle Nahinfrarotspektroskopie (fNIRS) eingesetzt [24]–[26]. Arousal lässt sich gut über peripher-physiologische Reaktionen wie der elektrodermalen Aktivität (Schweißbildung auf der Haut) und Herzratenvariabilität abbilden.

Mentale Belastung und Arbeitsgedächtnis

Mentale Belastung (engl. mental workload) beschreibt die geistige Beanspruchung, die bei der Ausführung einer (Arbeits-)Aufgabe entsteht [27]. Zumeist geht eine erhöhte Belastung mit der verstärkten Inanspruchnahme des Arbeitsgedächtnisses einher, beispielsweise während der Nutzung neuartiger Benutzungsschnittstellen bei der Produktionsarbeit. Um die Komplexität von Arbeitsaufgaben und Benutzungsschnittstellen zu bewerten, kann der Grad der Belastung sowohl subjektiv über Fragebögen als auch objektiv mittels neurophysiologischer Methoden wie der EEG oder Pupillendilatation erfasst werden [28]. Neurophysiologische Verfahren haben den Vorteil, dass Messwerte kontinuierlich erhoben werden können, ohne dass die Nutzer*innen die Arbeitsaufgabe unterbrechen müssen [29], [30]. Dies liefert die Voraussetzung für die Entwicklung intelligenter Systeme, die Nutzer*innen kognitiv entlasten, indem sie sich adaptiv an ihre aktuellen kognitiven Kapazitäten anpassen. Forschungsthemen im Zusammenhang mit beanspruchungsadaptiven Systemen umfassen die Realisierung in konkreten Praxisszenarien sowie deren Nutzerakzeptanz und quantitativ erfassbaren Verbesserungen, die durch sie erreicht werden können [31]–[34].

Aufmerksamkeit und Interesse

Aufmerksamkeitssteuerung sowie die exekutiven Funktionen des Arbeitsgedächtnisses sind wesentliche Voraussetzungen für die Selbstregulation und das zielgerichtete Handeln. Neurowissenschaftliche Methoden können eingesetzt werden, um die Belastung exekutiver Funktionen im Arbeitsgedächtnis (wie Inhibition, Updating oder Shifting) zu erkennen [28], [35]. Die Forschungsschwerpunkte umfassen die Erkennung von Informationsrelevanz (z. B. bei der Internet-suche), von Informationskonflikten (z. B. bei Text-Bild-Kombinationen) und von Aufmerksamkeitsintensität bei der Informationsenkodierung (z. B. beim Betrachten von Bildern). Diese psychologischen Konstrukte sind insbesondere im Zusammenhang mit der optimalen Gestal-

tung von adaptiven Wissensmedien und Lernumgebungen relevant. In realistischen Wissenserwerbsituationen wie dem Lesen von Texten, der Bearbeitung von Mathematikaufgaben, der Suche nach Informationen im Internet oder dem Lernen mit Multimedia können physiologische Methoden wie EEG, fNIRS, Eyetracking (Pupillometrie) oder Touchsensorik eingesetzt werden, um relevante Lernzustände anhand spezifischer physiologischer Signaturen zu erkennen und als Grundlage für Systemanpassungen zu nutzen.

Aufgabenbezogenes Engagement

Der Begriff »Human-in-the-loop« bezeichnet die Einbindung von menschlichen Operator*innen in die Echtzeitmessung und Modellierung von Mensch-Maschine-Systemen. Von besonderem Interesse ist hierbei die Aufgabenzuwendung (engl. Task Engagement). Diese hängt sowohl von der Schwierigkeit der Kontrollaufgabe als auch vom Konzentrationsvermögen und der Ablenkbarkeit ab. Die Aufgabenzuwendung bestimmt, wie effizient einzelne Operator*innen relevante Informationen aufnehmen, verarbeiten und Handlungsanweisungen an die Maschinenkomponente des Systems übersetzen. Zu hohe, aber auch zu niedrige Grade von Aufgabenzuwendung vermindern das Situationsbewusstsein und beeinträchtigen somit beispielsweise die Ausführung angemessener Notfallmanöver in kritischen Situationen.

Neurophysiologische (z. B. EEG und fNIRS) und peripher-physiologische Messmethoden (z. B. Hautleitwiderstands- und Herzfrequenzvariabilitätsmessung) werden eingesetzt, um die Aufgabenzuwendung in komplexen, teilautomatisierten Maschinenkontrollszenarien zu erfassen. Darauf aufbauend sollen Mensch-Maschine-Schnittstellen entwickelt werden, die die Aufgabenzuwendung im optimalen Bereich halten, indem sie sich kontinuierlich an die einzelnen Operator*innen anpassen und Aufgabenbestandteile adaptiv an die Maschinenkomponente auslagern [36]–[38].

Fehlererkennung in Handlung und Wahrnehmung

Macht eine Person einen Fehler oder beobachtet sie eine andere Person bei einer fehlerhaften Aktion, so lässt sich diese Fehlererkennung in den Hirnsignalen der Person identifizieren [39]–[42]. Auch wenn sich die Reaktion auf Fehler zwischen verschiedenen Aufgaben unterscheidet, so ist sie dennoch universell erkennbar. Mittels Maschinellem Lernmethoden kann diese Gehirnreaktion auf Fehler in Echtzeit erfasst werden. Dies kann zum Beispiel für ein adaptives Mensch-Technik-System genutzt werden, das die Fehler des Systems, die die Benutzer*innen erkennen, automatisch selbst korrigiert.

Da die menschliche Fehlererkennung eng mit Lernmechanismen gekoppelt ist, bietet sich eine Nutzung dieser Fehlererkennung besonders im Bereich des Lernens an. So konnte anhand der im EEG identifizierten Hirnsignale auf Fehler gezeigt werden, dass unterschiedliche Lerntypen existieren und identifiziert werden können. Diese Informationen können verwendet werden,

FEINFÜHLIGE TECHNIK – EINE »ANNÄHERUNG« VON MENSCH UND TECHNIK?

um den Lernstoff individuell an die einzelnen Lernenden anzupassen. Durch eine automatisierte Auswertung der Hirnsignale kann das Lernmaterial auch stetig während der Interaktion an die Fähigkeiten oder den Fortschritt der Lernenden zugeschnitten werden. Mechanismen, die anhand der Hirnsignale detektieren, ob eine Person einen Fehler erkannt hat, können auch dafür genutzt werden, das Verständnis der Lernenden zu diagnostizieren und Einzelnen daraufhin adaptiv neue Lerninhalte anzubieten, wenn sie den bisherigen Inhalt ausreichend verstanden haben.

Zusammenfassend gibt die nachfolgende Tabelle einen Überblick über die verschiedensten Sensortechnologien, eine kurze Beschreibung, was diese Verfahren messen und welches psychologische Konstrukt diese erkennen können (Tabelle 1).

*Tabelle 1: Zusammenfassung
über die verschiedenen
Sensortechnologien, deren
Funktionsweise und damit mess-
bare psychologische Konstrukte.*

Sensor	Beschreibung	Psychologisches Konstrukt
Elektroenzephalographie (EEG)	Messung der Hirnaktivität über elektrophysiologische Signale durch Elektroden auf der Kopfhaut (gelbasiert oder trocken). Gute zeitliche Auflösung: Wann ändert sich die Hirnaktivität? Schlechte räumliche Auflösung: Wo ändert sich die Hirnaktivität?	Affekt/Emotion, mentale Belastbarkeit, Arbeitsgedächtnis, Aufmerksamkeit/Interesse, Fehlererkennung in Handlung und Wahrnehmung, aufgabenbezogenes Engagement
Funktionelle Nahinfrarotspektroskopie (fNIRS)	Messung der Hirnaktivität durch hämodynamische Eigenschaften der Neurone (Sauerstoffveränderung im Blut) durch die Detektion der Menge an absorbiertem Nahinfrarotlicht. Eine erhöhte Aktivität der Neurone bedeutet eine erhöhte Menge an Sauerstoff im Blut, was zu einer geringeren Absorptionsrate des Nahinfrarotlichts führt. Gute räumliche Auflösung Schlechte zeitliche Auflösung	Affekt/Emotion, Aufmerksamkeit/Interesse, aufgabenbezogenes Engagement
Elektrokardiographie (EKG)	Messung elektrischer Spannungsänderungen des Herzens, entstehend durch die Kontraktion des Herzmuskels mittels auf der Haut angebrachter Elektroden. Spannungsänderungen geben Informationen über aktuelle kognitive und affektive Zustände der Person.	Affekt/Emotion, aufgabenbezogenes Engagement

Sensor	Beschreibung	Psychologisches Konstrukt
Elektromyographie (EMG)	Messung elektrischer Spannungsänderungen zwischen Muskeln durch oberflächlich angebrachte Elektroden oder invasive Elektroden direkt am Muskel.	Emotion (durch Ableitung elektrischer Spannungsänderungen an den Gesichtsmuskeln)
Elektrodermale Aktivität (EDA)	Messung der Hautleitfähigkeit durch oberflächlich angebrachte Elektroden, die durch vermehrte Schweißproduktion erhöht wird.	Affekt/Emotion, aufgabenbezogenes Engagement
Blickerfassung	Erfassung von Blickbewegungen (Fixation oder Sakkaden) oder Pupillendilatation mithilfe einer Infrarotkamera, die die Position von Pupille und Cornea als helle Lichtreflektion erfasst und an eine Bildverarbeitungssoftware weiterleitet.	Aufmerksamkeit/ Interesse, Belastung des Arbeitsgedächtnisses
Gesichtsanalyse	Erkennung und Identifizierung von menschlichen Gesichtsausdrücken (anhand von angespannten oder entspannten Gesichtsmuskeln) mithilfe einer Kamera und spezieller Software. Einteilung in: Freude, Wut, Ekel, Angst, Traurigkeit und Überraschung.	Emotion

2.2.3 Technische Grundlagen einer feinfühligten Technik

Um von der Kenntnis der neuropsychologischen Konstrukte zu praxistauglichen Anwendungen einer feinfühligten Technik zu gelangen, sind Forschungs- und Entwicklungsaktivitäten zu den technischen Grundlagenthemen wie der Datenbereinigung, Datenfusion, Echtzeitsignalverarbeitung und dem Maschinellen Lernen erforderlich.

Datenbereinigung

Bevor die peripher- und neurophysiologischen Signale mittels Algorithmen des Maschinellen Lernens (ML) analysiert werden, bedarf es einer Vorverarbeitung zur Artefaktbereinigung, Verbesserung des Signal-Rausch-Verhältnisses und Extraktion relevanter Merkmale.

Datenfusion

Die robuste Erkennung von Nutzerzuständen (entlang der oben genannten Konstrukte) erfordert die gemeinsame Auswertung von Daten aus verschiedenen Quellen. Dies liegt einerseits an manchen der Konstrukte, wenn sich diese nur über die Kombination verschiedener Maße erschließen lassen (z. B. Valenz und Arousal für Emotionsmessung). Andererseits lässt sich die Genauigkeit und Zuverlässigkeit der Messungen erhöhen, wenn mehrere konvergierende Verfahren gleichzeitig eingesetzt werden. So können zum Beispiel Defizite einzelner Verfahren

durch die Kombination mit anderen Verfahren kompensiert werden (z. B. EEG mit hoher zeitlicher und schlechter räumlicher Auflösung in Kombination mit fNIRS, dass genau die umgekehrten Stärken und Schwächen mit sich bringt).

Echtzeitsignalverarbeitung

Da neurophysiologische Grundlagenexperimente meist im Nachgang nach Beendigung der Messung ausgewertet werden (»offline«), ist die Verarbeitung der erfassten Signale zeitunkritisch. Bei einer »echtzeitfähigen« feinfühligem Technik ist es jedoch von essenzieller Bedeutung, dass Klassifikationsergebnisse ohne wahrnehmbare Verzögerung zu einer systemseitigen Reaktion führen. Nur so kann das adaptive System rechtzeitig und angemessen auf Änderungen des Nutzerzustands reagieren. Und nur so kann für Nutzer*innen ein ausreichendes Maß an Transparenz bezüglich der Ursache-Wirkungs-Zusammenhänge innerhalb des adaptiven Systems erreicht werden. Beispielsweise können Nutzer*innen auch in den Vorgang des Lernens eingebunden werden, indem das System sie nach jedem Lernschritt hinsichtlich einer Bewertung und weiterer Annotation (in Form einer Bestätigung oder Ablehnung) des erkannten Zustands auffordert. Bereits während der Datenaufnahme werden zeitliche und räumliche Filterung sowie Verfahren zur Vermeidung und Bereinigung von Artefakten angewendet, um das Signal für die Echtzeitverarbeitung mittels ML-Modelle vorzubereiten.

2.2.3.1 Maschinelles Lernen für die Analyse (neuro-)physiologischer Signale

Maschinelles Lernen (ML) und neurophysiologische Signale

Beim Maschinellen Lernen geht es darum, Computern die Fähigkeit zu verleihen, selbstständig zu lernen, ohne dass man diese ausdrücklich programmieren muss. Dieses Prinzip steht im Gegensatz zur klassischen Programmierung, bei der für gewöhnlich strikte Handlungsvorschriften nach einem Algorithmus befolgt werden. Schritt für Schritt werden Anweisungen und Regeln für die Ausführung des Computerprogramms programmiert. Ein System des Maschinellen Lernens kann mehr als das: Es sucht in eingehenden Daten nach Mustern, um auf zugrundeliegende Regeln zu schließen. Hierbei wird ein mathematisches Modell gelernt, um Regeln abzubilden. So lernt das System stets dazu, indem es mit jedem neuen Datenbestand seine Modelle und – so – seine *Sichtweise* der Welt aktualisiert. Diese Methoden des ML erlauben es, Unterschiede im gesamten Spektrum der hochkomplexen neurophysiologischen Signale sinnvoll und objektiv zu identifizieren. Diese Werkzeuge können darüber hinaus helfen, neurophysiologische Merkmale zu identifizieren, die eine Vorhersage der mentalen Prozesse ermöglichen. In der Tat wird auch argumentiert, dass Maschinelle Lernansätze theoretische Errungenschaften fördern und unser Verständnis von der Hirndynamik, die den mentalen Prozessen zugrunde liegt, verbessern können [43], [44].

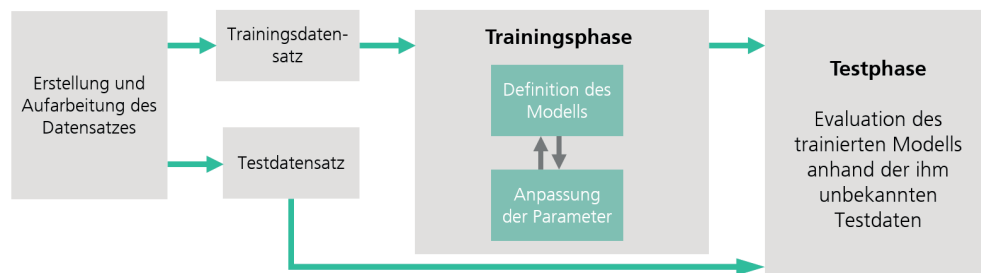


Neurophysiologische Daten weisen eine hohe Dimensionalität auf. Daher eignen sich Maschinelle Lerntechniken besonders gut, um bestimmte Muster in diesen Signalen zu identifizieren. Anhand dieser Muster bzw. Merkmale lassen sich in der Regel bestimmte Korrelate in den Hirn- und Körpersignalen, die mit einer Aufgabe oder einem Kontext assoziiert sind, erkennen (siehe auch Kapitel 2.2.3.2 für nähere Erläuterungen zur Merkmalsextraktion). Jedoch stellen sich bei der Anwendung des Maschinellen Lernens für die Analyse von (neuro-)physiologischen Signalen besondere Herausforderungen. Diese Herausforderungen umfassen: a) die hohe interindividuelle Variabilität (d. h. die Unterschiede in den Gehirn- und Körpersignalen zwischen Personen) und b) die Instabilität neuronaler Korrelate über verschiedene Kontexte und Kontextbedingungen (d. h. die Unterschiede in den Gehirn- und Körpersignalen zwischen Umgebungen, Anwendungen und Aufgaben).

Mithilfe von Maschinellen Lernalgorithmen ist es möglich, die hochkomplexen (neuro-)physiologischen Daten zu analysieren, und aus diesen Analysen Regeln in den Daten zu erkennen. Darauf basierend können Aussagen oder Vorhersagen über mentale Zustände getroffen werden. Damit ein Modell aus einem Datensatz lernen kann, bedarf es einiger wichtiger Schritte und Voraussetzungen (siehe auch Abbildung 2).

FEINFÜHLIGE TECHNIK – EINE »ANNÄHERUNG« VON MENSCH UND TECHNIK?

Abbildung 2: Ablauf eines typischen Maschinellen Lernverfahrens, bestehend aus der Aufarbeitung des Datensatzes, der Trainings- und Testphase.



1. Im ersten Schritt müssen genug Daten gesammelt und aufbereitet werden. Hierbei ist es wichtig, dass der Datensatz groß und vielseitig genug ist, sodass das Modell generalisierbar ist.
2. Des Weiteren sollten die Daten so aufbereitet sein, dass alle für die aktuelle Fragestellung wichtigen Merkmale identifiziert und aus den Signalen extrahiert werden können.
3. Ist dies der Fall, wird der Datensatz entweder in einen Trainings- und Testdatensatz aufgeteilt (im Fall des überwachten Lernens) oder dem Modell ganz übergeben (im Fall des unüberwachten Lernens). Der Trainingssatz dient dazu, das gewählte Modell zu trainieren, d.h. Parameter anzupassen und das Modell zu definieren. Der Testdatensatz wird dann verwendet, um das trainierte Modell auf unbekannten Daten zu testen und evaluieren.
4. Erzielt das Modell auf den Trainings- und Testdaten ungefähr die gleiche Genauigkeit (Fehlerrate), kann es auf neue unbekannte Daten angewandt werden.

Beim Trainieren eines Modells wird grundsätzlich zwischen zwei Arten unterschieden: (1) dem überwachten Lernen (engl. supervised learning), bei dem das Modell bekannte Daten mit Annotation verwendet, um Muster und Zusammenhänge zu erkennen und zu lernen, um dieses Wissen dann auf unbekannte Daten anzuwenden. Ziel ist es, Vorhersagen und Prognosen zu treffen. Im Gegensatz zum überwachten Lernen erhält das Modell beim (2) unüberwachten Lernen (engl. unsupervised learning) keine annotierten Daten (d.h. die Daten weisen keine Bezeichnung im Sinne einer Klasseninformation oder eines vorherzusagenden Wertes auf). Unüberwachte ML-Modelle identifizieren und lernen neue unbekannte Muster aus nicht-annotierten Daten. Im Gegensatz zum überwachten Lernen ist das unüberwachte Lernen also nicht dafür geeignet, Vorhersagen oder Prognosen für bestimmte Zielvariablen zu treffen. Abbildung 3 verdeutlicht die Unterschiede zwischen überwachtem und unüberwachtem Lernen.

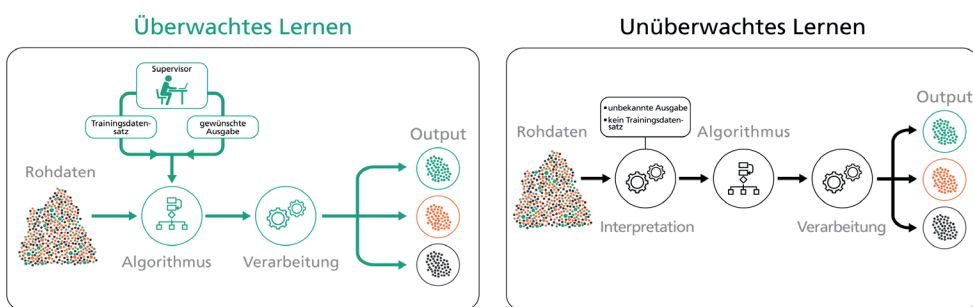


Abbildung 3: Visualisierung der Unterschiede bei überwachtem und unüberwachtem Lernen. Während im Falle des überwachten Lernens Annotationen für die Daten vorliegen, lernt ein unüberwachter Lernalgorithmus eigenständig Muster und Zusammenhänge in den Daten, die danach mit Domänenwissen zu interpretieren sind⁴.

Die Annotation beim überwachten Lernen wird auch Label genannt und kann einerseits die Klasseninformation bei einem Klassifikationsproblem oder den Wert darstellen, den das Modell bei einem Regressionsproblem vorhersagen möchte, z. B. den Score in einem Test oder eine physikalische Größe eines Qualitätsindikators.

Je nach Fragestellung kann zwischen verschiedenen Algorithmen gewählt werden, die im Nachfolgenden kurz erläutert werden (Abbildung 4).

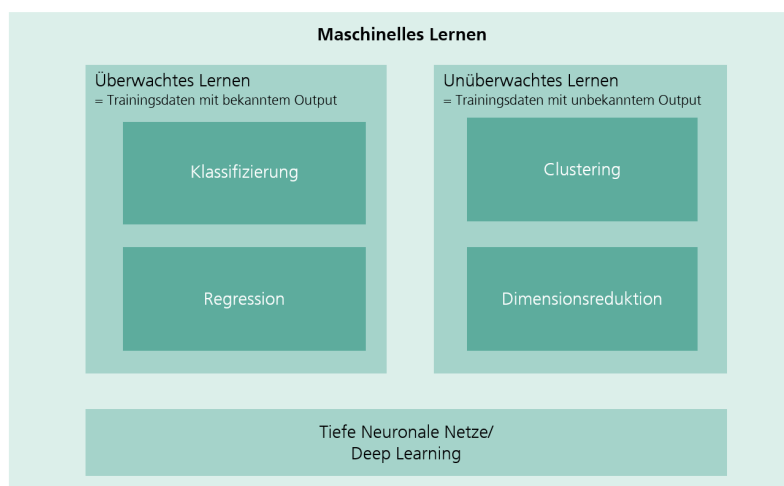


Abbildung 4: Überblick über Maschinelles Lernen, unterteilt in überwachtes und unüberwachtes Lernen, sowie die dazugehörigen Verfahren des Maschinellen Lernens (Klassifizierung, Regression, Clustering, Dimensionsreduktion)⁵.

⁴ In Anlehnung an: <https://datafloq.com/read/machine-learning-explained-understanding-learning/4478#>, aufgerufen am: 01.12.2020.

⁵ In Anlehnung an: <https://towardsdatascience.com/artificial-intelligence-framework-a-visual-introduction-to-machine-learning-and-ai-d7e36b304f87>, aufgerufen am: 27.10.2020.


Überwachtes Lernen

Das überwachte Lernen ist die häufigste Methode, wenn es darum geht (neuro-)physiologische Signale zu analysieren. Hierzu werden annotierte Daten einem maschinellen Lernalgorithmus zur Verfügung gestellt, um daraus Muster und Zusammenhänge zu erkennen. Die Zielvariable kann hierbei entweder eine Klasse (Klassifikation) oder ein numerischer Wert (Regression) sein. So wird durch eine Klassifikation vorhergesagt, ob z. B. einzelne Nutzer*innen positive Emotionen bei der Interaktion mit einer Technologie empfinden oder nicht (diskrete Werte), während eine Regression vorhersagt, wie stark die jeweiligen Nutzer*innen emotional auf eine Technologie reagieren (kontinuierliche Werte).



Klassifikation

Wenn Datenpunkte vorgegebenen Kategorien zugeordnet werden sollen, spricht man von Klassifikation. Dabei können nur zwei Kategorien (binäre Klassifikation) oder beliebig viele Kategorien definiert sein.



Regression

Ziel der Regression ist es, die Beziehung zweier oder mehrerer Variablen zu beschreiben, um z. B. einen Wert basierend auf dem Eingabewert vorherzusagen. Dieses Verfahren eignet sich also vor allem, um Vorhersagen und Prognosen aus den gegebenen Daten abzuleiten. Die Regression kann dabei eine Zielvariable mit einer oder mehreren unabhängigen Variablen in Verbindung setzen. Die gängigste Form der Regression ist die *lineare Regression*, bei der ein linearer Zusammenhang zwischen Ziel- und unabhängiger Variable untersucht wird.

Für beide Problemstellungen – Klassifikations- und Regressionsprobleme – stehen verschiedene Algorithmen zur Verfügung, die sich hinsichtlich ihrer Anforderungen an die Daten und Vorgehensweise unterscheiden.

Die Algorithmen für Klassifikations- und Regressionsprobleme lassen sich in verschiedene Gruppierungen einteilen, wobei die bekanntesten folgende sind: (1) lineare Methoden, wie z. B. die logistische Regression (Klassifikation), lineare Regression (Regression) oder Support-Vektor-Maschinen mit linearem Kernel, (2) nicht lineare Methoden, wie z. B. Support-Vektor-Maschinen mit radialer Basisfunktion als Kernel, (3) Ensemble-Methoden, wie z. B. Random Forests oder Entscheidungsbäume, die sich besonders aufgrund ihrer Erklärbarkeit und ihres geringen Anspruchs an Datenaufbereitungsschritten eignen, (4) Probabilistische Methoden, wie z. B., Naive Bayes, und (5) tiefe neuronale Netze (u.a. faltende neuronale Netzwerke oder rekurrente neuronale Netze).

Unüberwachtes Lernen

Clusteranalyse

Sollen Datenpunkte nach ihren Gemeinsamkeiten gruppiert werden oder neue, noch unbekannte Gruppen innerhalb der Daten identifiziert werden, wird eine Form des unüberwachten Lernens angewandt, die man als Clusteranalyse bezeichnet. Der bekannteste Algorithmus zur Clusteranalyse ist der sogenannte *k-Means-Algorithmus*, bei dem zu Beginn festgelegt wird, wie viele Cluster (k) definiert werden sollen. Eine Erweiterung des k -Means ist der Fuzzy- c -Means-Algorithmus (auch »Algorithmus der c -unscharfen Mittelwerte« genannt). Für kategoriale Daten wurden weitere Methoden wie z. B. der k -Mode- oder k -Prototype-Algorithmus entwickelt, um die Abstände zwischen zwei Datenpunkten adäquat zu bestimmen. Zu Beginn werden die Mittelpunkte jedes Clusters zufällig in der Datenmenge ausgewählt und jeder Datenpunkt wird dann dem ihm am nächsten liegenden Cluster zugeordnet. Dann werden aus den zugeordneten Datenpunkten jeweils die neuen Mittelpunkte für jedes Cluster berechnet. Dieser Vorgang wiederholt sich so lange, bis sich die neuen Mittelpunkte nicht mehr von den vorherigen unterscheiden – die Cluster sind definiert.

Dimensionsreduktion

Oftmals ist es bei (neuro-)physiologischen Signalen der Fall, dass die vorhandenen Datenpunkte Merkmale aufweisen, von denen viele für das Training des Modells irrelevant sind. Die gängigste Methode des unüberwachten Lernens in der Analyse von (neuro-)physiologischen Signalen ist die Dimensionsreduktion. Eine Dimensionsreduktion verringert diese große Anzahl an Merkmalen, indem sie einzelne Merkmale in aussagekräftigere Linearkombinationen umwandelt. Eins der bekanntesten Verfahren ist die Hauptkomponentenanalyse (engl. *Principal Component Analysis – PCA*). Sie dient dazu, extrem große Datenmengen visualisierbar zu machen, um dann versteckte Muster in diesen Datenmengen zu erkennen.

Künstliche neuronale Netze

Künstliche neuronale Netze bestehen nach dem Vorbild des Gehirns aus einem Netzwerk simulierter Nervenzellen, sogenannter Knoten, die in Schichten hintereinander angeordnet sind. Diese verarbeiten entweder Informationen von außen oder nehmen Informationen von anderen Neuronen auf und verarbeiten diese weiter. Somit besteht ein neuronales Netz aus mehreren »Schichten«, die eine Matrix-Vektor-Multiplikation durchführen, gefolgt von der Anwendung einer nichtlinearen »Aktivierungsfunktion«. Dabei sind die Matrizen des neuronalen Netzes die erlernbaren Parameter des Modells und werden als »Gewichte« des neuronalen Netzes bezeichnet. In der einfachsten Form besteht ein künstliches neuronales Netz aus einer Eingabeschicht, einer verborgenen Schicht und einer Ausgabeschicht. Dabei wird der Input (Eingabe

von Daten) von Neuronen der Eingabeschicht aufgenommen, verarbeitet und an die nächste verborgene Schicht weitergeleitet. In dieser findet dann eine erneute Verarbeitung statt. Schließlich wird die resultierende Entscheidung in der Ausgabeschicht ausgegeben.


Somit lassen sich mithilfe von künstlichen neuronalen Netzen Daten interpretieren und Muster extrahieren, um dann Vorhersagen für die Zukunft zu treffen. Die neuronalen Netze können sich stark in ihrer Struktur unterscheiden und somit unterschiedlich komplex sein. Ist ein neuronales Netz besonders tief aufgebaut, sprich mehrere verborgene Schichten hintereinandergeschaltet sind, bezeichnet man dies auch als tiefes neuronales Lernen (engl. Deep Learning). Dabei unterscheiden sich die modernen Deep-Learning-Netzwerke von den neuronalen Netzen, die bereits in den 1980er-Jahren entwickelt wurden, im Wesentlichen nur durch die schiere Anzahl an Knoten und Schichten. Die leistungsfähigsten der heutigen Deep-Learning-Systeme zeichnen sich durch Millionen oder gar Milliarden von Knoten aus, die in bis zu 30 bis 40 Schichten gestapelt werden können [45].

2.2.3.2 Unterschied in der Mustererkennung beim traditionellen Maschinellen Lernen und in Tiefen neuronalen Netzen bei (neuro-)physiologischen Signalen

Die Mustererkennung ist eine spezielle Form der maschinellen bzw. automatischen Informationsverarbeitung, bei der es um die Nachbildung der perzeptiven Fähigkeiten von Lebewesen geht. Im weitesten Sinne erfasst es die mathematisch-technischen Aspekte von Perzeption durch Maschinen bzw. Computer. Sowohl Maschinelles Lernen als auch Deep Learning helfen dabei, latente Muster in Daten zu entdecken. Jedoch unterscheiden sich die Ansätze stark in den Techniken und Anwendungsbereichen. Maschinelles Lernen und Deep Learning sind beides Teilbereiche der KI-Forschung. Dabei ist Deep Learning eine spezielle Art des Maschinellen Lernens. Beide beginnen mit der Aufteilung der Eingabedaten in Trainings- und Testdaten, dem Anpassen eines Modells und dem Optimieren von Modellparametern. Beide können numerische (Regression) und nicht-numerische (Klassifizierung) Probleme behandeln. Jedoch gibt es einige spezialisierte Anwendungsbereiche, in denen Deep-Learning-Techniken deutlich besser abschneiden. Dazu gehören Anwendungen im Bereich der Computer Vision oder dem Natural Language Processing (Sprachverarbeitung) [46]–[50].

Neurotechnologien, wie z. B. EEG- oder fNIRS-Systeme, erfassen Informationen über sehr unterschiedliche Aspekte unserer Kognition, Emotionen und unseres Verhaltens. Allerdings sind diese Daten nicht immer einfach zu interpretieren: Sie sind stark verrauscht, variieren erheblich zwischen einzelnen Personen und ändern sich selbst bei derselben Person im Lauf der Zeit erheblich. Betrachtet man zum Beispiel das EEG-Signal, das ein sehr komplexes Signal ist, so erfordert es hier in der Regel mehrere Jahre an Training sowie fortschrittlichster Signalverarbeitungs- und Merkmalsextraktionsmethoden, um es korrekt zu interpretieren [51]–[53]. Bevor die (neuro-)

physiologischen Signale mittels Maschinellen Lernens interpretiert werden können, bedarf es in der Regel einer Vorverarbeitung zur Artefaktbereinigung, Verbesserung des Signal-Rausch-Verhältnis und Extraktion relevanter Merkmale. Abbildung 5 zeigt dieses klassische Vorgehen am Beispiel des EEG-Signals. Die Standard-EEG-Pipeline besteht dabei aus Techniken der Signalverarbeitung und Maschinellen Lernen, um das Signal-Rausch-Verhältnis zu verbessern, mit EEG-Artefakten umzugehen, Merkmale zu extrahieren und Signale zu dekodieren und interpretieren.



So wie das Deep Learning in vielen Bereichen wie Computer Vision, Sprachverarbeitung oder Reinforcement Learning das Maschinelle Lernen enorm verändert hat, so bietet es auch großes Potenzial für die Neurowissenschaften: zur Dekodierung und Interpretation der komplexen (neuro-)physiologischen Signale [53]–[57]. Möglich macht dies im Allgemeinen die Flexibilität, die diese Modelle bereitstellen, indem sie mit Rohdaten arbeiten und die passenden Transformationen (Merkmalsextraktion) für ein bestimmtes Problem selbstständig bewältigen können. So können diese Modelle große Mengen von (neuro-)physiologischen Daten nutzen, um direkt Merkmale zu lernen. Die Datenstruktur kann dadurch auf effiziente Weise erfasst und auf verschiedene Aufgaben übertragen oder angepasst werden. Diese durchgängige Lernfähigkeit eignet sich sehr gut für die Anforderungen der (neuro-)physiologischen Datenanalysen. Beispielsweise sind beim EEG mehrere voneinander abhängige Prozesse entscheidend, und Auswertungen wurden bis vor Kurzem sorgfältig für jeden unterschiedlichen Anwendungszweck entwickelt. Eine aktuelle Metaanalyse bietet einen Überblick der wissenschaftlichen Arbeiten der letzten zehn Jahre zu Deep-Learning-Techniken am Beispiel des EEGs [54].

Abbildung 5: Illustratives Beispiel der Standard-Pipeline anhand des EEGs. Die multivariaten Zeitreihen des EEGs enthalten in ihrem ursprünglich gemessenen Zustand Signal-Drifts, elektromagnetisches Rauschen und weitere unspezifische Artefakte, die mit den eigentlichen zu interessierenden neuronalen Signalen nichts zu tun haben. Diese Artefakte werden im Schritt der Vorverarbeitung entfernt. Nach der Vorverarbeitung werden aussagekräftige Merkmale aus den bereinigten EEG-Daten extrahiert. Danach werden die Informationen zur automatischen Dekodierung (Klassifikation oder Regression) des EEGs genutzt. Der häufigste Ansatz dabei ist das überwachte Lernen.

FEINFÜHLIGE TECHNIK – EINE »ANNÄHERUNG« VON MENSCH UND TECHNIK?




Abbildung 6: Statistik über Deep-Learning-Techniken, angewendet auf EEG-Daten. Anzahl der Publikationen pro Anwendungsbereich pro Jahr (links) und Art der verwendeten Architekturen (rechts)⁶.

Abbildung 6 zeigt die Hauptanwendungsgebiete der bisherigen Deep-Learning-basierten EEG-Datenanalysen, und welche Modelle am häufigsten verwendet wurden. Es ist ersichtlich, dass es hier noch keine klar dominierende Architektur gibt. Viele der auf das EEG angewendeten Modelle wurden direkt aus früheren Anwendungen, wie zum Beispiel Computer Vision, entlehnt. Daher sind faltende neuronale Netzwerke (engl. convolutional neural networks) die am häufigsten verwendete Architektur, gefolgt von Autoencodern und rekurrenten neuronalen Netzen (engl. recurrent neural networks). Obwohl die absolute Zahl der Deep-Learning-EEG-Publikationen im Vergleich zu anderen klassischen Deep-Learning-Anwendungen wie der Computer Vision relativ gering ist, besteht eindeutig ein wachsendes Interesse, wie die Grafik verdeutlicht. Allein in den ersten sieben Monaten des Jahres 2018 wurden mehr Publikationen gezählt als in den Jahren 2010 bis 2016 zusammen, was die Relevanz dieser Übersicht verdeutlicht [54]. Es ist jedoch noch zu früh, um auf Trends in den Anwendungsbereichen zu schließen, da die Anzahl der bisherigen Veröffentlichungen relativ gering ist.

Zusammenfassend gibt die nachfolgende Abbildung 7 den wesentlichen Unterschied zwischen dem klassischen Maschinellen Lernen und Deep Learning wieder.


⁶ Grafik entnommen aus dem Metareview aus Yannick Roy et al 2019 J. Neural Eng. 16 051001 [54]

Merkmalsextraktion in tiefen neuronalen Netzen (Deep Learning)

Während klassische Methoden des Maschinellen Lernens die sorgfältige Aufbereitung und Auswahl von informativen Merkmalen (engl. feature engineering) bedürfen, können tiefe neuronale Netze innerhalb ihrer verborgenen Schichten diese hierarchischen Repräsentationen (Merkmale unterschiedlichster Komplexität) eigenständig aus den Daten lernen. So sind sie hervorragend geeignet, selbstständig Abstraktionen mit unterschiedlichen Komplexitätsgraden zu erfassen. Dabei können sie Muster und Regelmäßigkeiten in Daten lernen, sodass eine große Datenmenge effektiv komprimiert wird, während die wichtigsten Informationen erhalten bleiben.



Klassisches Maschinelles Lernen



Deep Learning




Abbildung 7: Traditionelles Maschinelles Lernen (oben) verwendet »vordefinierte« Merkmale (Merkmal-Engineering), deren Entwicklung mühsam und kostspielig sein kann. Deep Learning (unten) lernt hierarchische Repräsentationen aus den Daten selbst und skaliert mit mehr Daten. Beim einem Deep-Learning-Netzwerk werden Merkmalsextraktion und Klassifikation in einem Schritt durchgeführt.

2.2.4 Brain-Computer-Interfaces und neuro-adaptive Systeme

2.2.4.1 Brain-Computer-Interfaces: Einführung und Definition

Aus technologischer Sicht sind Computer und Maschinen zunehmend in der Lage zu lernen, zu kommunizieren und Entscheidungen zu treffen. Dadurch gewinnt die Interaktion zwischen Menschen und Technik an zusätzlicher Dynamik. Sprach-, Gesten- und Mimikererkennung ersetzen zunehmend frühere Eingabegeräte wie Maus und Tastatur. Es gibt stetige Fortschritte in der Entwicklung von Sensortechnologien und Miniaturisierung von Techniken zur Aufzeichnung peripher- und neurophysiologischer Aktivität in Verbindung mit fortgeschrittener Signalverarbeitung, Statistik und Maschinellem Lernen. Auf diese Weise lassen sich aus den erfassten Signalen viele Facetten mentaler Nutzerzustände ableiten (siehe vorheriges Kapitel für einen

ergiebigem Überblick). Auf der Grundlage dieser Entwicklungen haben wir in den letzten Jahrzehnten ein enormes Verständnis von den kognitiven Funktionen und emotionalen Prozessen gewonnen, die der Wahrnehmung, Entscheidungsfindung, dem menschlichen Verhalten und sozialen Interaktionen zugrunde liegen. Um die Idee einer feinfühligsten Technik bzw. einer symbiotischen Interaktion zwischen Mensch und Maschine zu realisieren, bedarf es einer unmittelbaren und direkten Kommunikation zwischen Mensch und System. Eine Schlüsselerfindung stellt hier die Gehirn-Computer-Schnittstelle dar. Im Folgenden wird der englische Begriff Brain-Computer-Interface (BCI) verwendet.



Brain-Computer-Interface (BCI), deutsch Gehirn-Computer-Schnittstelle, ist eine technische Verbindung zwischen dem Gehirn und einem Computer. Ein BCI nutzt Sensoren zur Messung von Hirnsignalen, die im Gehirn (implantierte Elektroden) oder an der Kopfoberfläche angebracht werden (z. B. die Elektroenzephalographie). Mittels Maschineller Lernverfahren können diese Signale verarbeitet und so interpretiert werden, dass ein Computer sie dann für eine Aktion nutzen kann.

Grundlage des BCI sind Technologien zur Echtzeiterfassung neurophysiologischer Aktivitäten, die sich in *invasive* (z. B. Elektroden direkt im Muskel oder im Gehirn) und *nicht-invasive* (z. B. Elektroden auf der Hautoberfläche) Messtechniken unterteilen lassen [17], [58]. Der Vorteil invasiver BCIs liegt vor allem in der hohen Genauigkeit, mit der die entsprechenden Signale vom Muskel oder Gehirn abgeleitet werden können.

Allerdings erfordern invasive Aufzeichnungstechniken einen chirurgischen Eingriff, um Elektroden direkt in das Gehirn zu implantieren. Diese Aufzeichnungen werden weiter unterteilt in Gehirn-Oberflächenelektroden, wie z. B. die Elektrocortikographie (ECoG) und hirndurchdringende Mikroelektroden, siehe nachfolgende Abbildung.




Abbildung 8: Verschiedene Arten, Hirnsignale invasiv und nicht-invasiv über ein Brain-Computer-Interface (BCI) zu erfassen. EEG (Elektroenzephalographische) Signale werden von der Kopfhaut, ECoG (Elektrocorticographie) von der Gehirnoberfläche und LFPs (Local-field Potentials) und neurale Aktionspotenziale (Spikes) von hirndurchdringenden Elektroden aufgezeichnet.

Jedoch sei zu erwähnen, dass sich invasive BCIs nur für medizinische Zwecke eignen, da sie immer mit einem risikobehafteten chirurgischen Eingriff einhergehen und der regelmäßigen Betreuung durch medizinisches Fachpersonal bedürfen. Im Weiteren wird daher auf nicht-invasive BCIs eingegangen, da sich diese auch für nicht-medizinische Anwendungen eignen.

Wie bereits in Kapitel 2 anhand der Erkennungstechnologien eingeführt, lassen sich nicht-invasive BCIs in *i) tragbare Messtechniksysteme*, wie Elektroenzephalographie (EEG) und funktionelle Nahinfrarotspektroskopie (fNIRS) und *ii) stationäre Messtechniksysteme* wie Magnetoenzephalographie (MEG) und funktionelle Magnetresonanztomographie (fMRT) unterteilen. EEG und MEG ermöglichen die Messung der elektromagnetischen Aktivität mehrerer kortikaler Neuronen direkt durch die Aufzeichnung von Spannungsschwankungen über Elektroden auf der Kopfhaut (EEG) oder durch den Einsatz sehr empfindlicher supraleitender Sensoren (sogeannter SQUIDS, supraleitende Quanteninterferenzgeräte im MEG). Sowohl fMRT als auch fNIRS messen die neuronale Aktivität indirekt. Diese Techniken erfassen Stoffwechselvorgänge im Zusammenhang mit neuronaler Aktivität, indem sie hämodynamische Veränderungen im Blutfluss aufzeichnen. Dadurch ermöglichen sie die präzise Lokalisierung der Aktivierung und Deaktivierung bestimmter Hirnregionen.

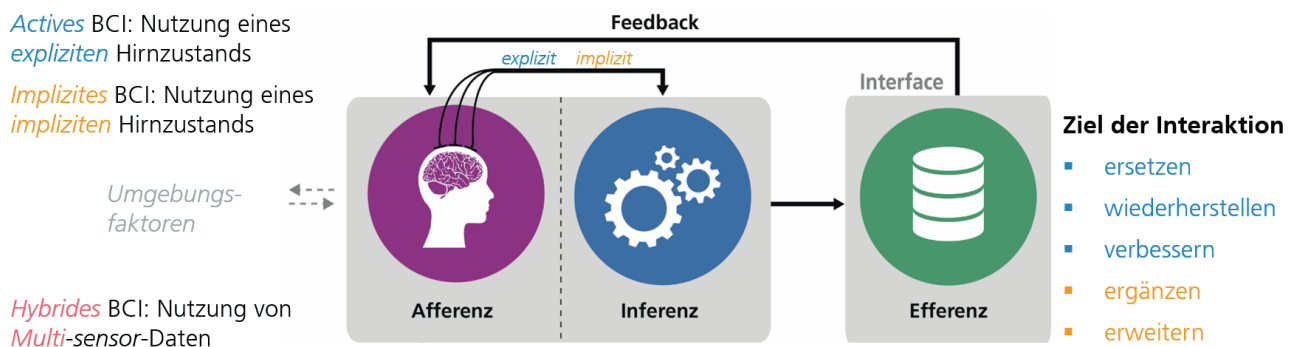
7 Grafik entnommen aus Nitish V. Thakor. *Science Translational Medicine*, 06 Nov 2013 [58].

© C. Bickel/Science Translational Medicine

FEINFÜHLIGE TECHNIK – EINE »ANNÄHERUNG« VON MENSCH UND TECHNIK?

Jedes BCI-System besteht im Wesentlichen aus drei funktionalen Komponenten (siehe dazu auch die nachfolgende Abbildung 9):

- **Afferenz:** Sammlung von verfügbaren und beobachtbaren Daten über einzelne Nutzer*innen und den Nutzungskontext anhand multimodaler Neurotechnologien (z. B. in Form eines hybriden Ansatzes).
- **Inferenz:** Klassifikation und Interpretation relevanter Eigenschaften der Nutzer*innen und des Nutzungskontexts aufgrund der gesammelten neurophysiologischen Daten durch Signalverarbeitung und Maschinelles Lernen.
- **Efferenz:** Entscheidung über das Adaptationsverhalten des technischen Systems und Ausführung der Anpassung aufgrund des kognitiven und/oder emotionalen Zustandes der einzelnen Nutzer*innen und somit transparentes Feedback über das Systemverhalten an die Nutzer*innen.



Definition in Anlehnung an »The future of brain/neural computer interaction: Horizon 2020: Technical Report April 2015«, <http://bnci-horizon-2020.eu/>

Abbildung 9: Definition der drei verschiedenen Typen von Brain-Computer Interfaces (BCI), aktiv, implizit und hybrid und deren jeweiliges Ziel für die Mensch-Technik-Interaktion (farbliche Zuordnung der Typen zu den Interaktionszielen; für detaillierte Beschreibungen siehe den nachfolgenden Text).

2.2.4.2 Aktives Brain-Computer-Interface und medizinische Anwendungen

Seit ihren Anfängen in den 1970er-Jahren [59] konzentrierte sich die BCI-Forschung vor allem auf klinische und medizinische Anwendungen. Hauptziel war es, Anwender*innen mit körperlichen oder sensorischen Einschränkungen ein Kommunikations- oder Hilfswerkzeug zur Verfügung zu stellen. So lassen sich technische Geräte zur computerbasierten Kommunikation oder Fortbewegung steuern, z. B. bei Locked-in- oder Schlaganfallpatienten. Bei solchen Anwendungen werden bestimmte psychische Zustände, die Anwender*innen freiwillig und willentlich erzeugen, unter Umgehung jeglicher Muskelaktivität dekodiert [60]–[65]. Aktive BCIs ermöglichen so die Entwicklung von assistiven und restaurativen Technologien zur Steuerung von Rollstühlen [66], Orthesen [67]–[69], Prothesen [70], Servicerobotern [71] und assistiven Web-Anwendungen [72]. Neben der aktiven Steuerung für Anwender*innen mit motorischen

Beeinträchtigungen sind BCIs auch für das Neurofeedbacktraining einsetzbar, zum Beispiel zur Behandlung von Patient*innen mit psychiatrischen Störungen wie Depression, Schizophrenie oder Aufmerksamkeitsdefiziten [73]–[77].

Fortschritte in der BCI-Forschung haben zu einem Aufschwung mobiler Technologien und hoch entwickelter Maschinellem Lernverfahren geführt, die weiter genutzt werden können, um die Grundlage für nicht-medizinische Anwendungen von BCIs zu schaffen [51], [52], [78], [79].

2.2.4.3 Implizites Brain-Computer-Interface und Kontextbewusste Systemanwendungen

In unserem Alltag werden technische Systeme immer wichtiger und dienen dazu, uns in der täglichen Routine zu unterstützen. Ein Teil der interaktiven Maschinen und adaptiven Systeme beziehen Informationen aus dem Interaktionsverhalten der Benutzer*innen [78] durch integrierte Sensoren (z. B. Smartphones) oder Umweltsensoren (z. B. Kameras) [80]–[82]. Solche intelligenten Systeme werden unter dem Begriff *kontextbewusste Systeme* (engl. context-aware systems) zusammengefasst [83], [84].

»Durch implizite Brain-Computer-Interfaces lassen sich Systemanwendungen von rein kontextbewussten zu empathisch-sensitiven Systemen weiterentwickeln.«

Kontextbewusste Systeme sind in der Lage, die Interaktion auf Basis der aktuellen Kontextinformationen (u. a. Informationen über den Verwendungszweck, das zu erreichende Ziel und die Aufgaben) anzupassen. So sind diese Maschinen für physische Umgebungen, Orte und Situationen sensibel. Beispiele reichen von sehr einfachen Anpassungen wie der Adaptation der Bildschirmhelligkeit an die aktuelle Tageszeit und Umgebungsbeleuchtung über Spurhalte- und Abstandsassistenten in (teilautonomen) Fahrzeugen bis hin zu kooperierenden Industrie- und Servicerobotern für den häuslichen Gebrauch.

Damit eine feinfühligste Technik auch im Kontakt mit Menschen gewinnbringend eingesetzt werden kann, ist es wichtig, dass neben den Umgebungsbedingungen auch mentale Zustände, Präferenzen und Absichten der Nutzer*innen angemessen berücksichtigt werden [1], [85]. Technische Systeme benötigen daher ein Verständnis der Benutzer*innen, bzw. Informationen, die über die bloßen Notwendigkeiten zur Steuerung der Maschine hinausgehen. Nur wenn die Technik sensibel und prompt auf ihre Nutzer*innen reagiert, werden intelligente Systeme als kooperativ, sensibel und menschengerecht wahrgenommen und als Hilfestellung oder Partner akzeptiert.

In den letzten Jahren hat der Einsatz von Algorithmen des Maschinellen Lernens für die computergestützte Nutzermodellierung erheblich zugenommen [86]–[88]. Die Grundidee besteht darin, dass computergestützte Nutzermodelle feiner abgestufte Aspekte der Nutzer*innen wie Fähigkeiten und Präferenzen sowie kontextbezogene situative Veränderungen wie selektive Aufmerksamkeit, Arbeitsgedächtnisbelastung und den aktuellen emotionalen Zustand abbil-

FEINFÜHLIGE TECHNIK – EINE »ANNÄHERUNG« VON MENSCH UND TECHNIK?

den. Dies ermöglicht Systemanpassungen an komplexe Situationen ohne starre Abhängigkeit von vorgegebenen Programmen und Modellen [89], [90] und bietet die Grundlage für eine symbiotische Interaktion zwischen Mensch und intelligenter autonomer Technik.

Die Einführung passiver bzw. impliziter BCIs [91] als neues Konzept in Verbindung mit neuen mobilen und einsatzfähigen Sensortechnologien sowie fortschrittlichen Signalverarbeitungs- und Maschinellen Lernalgorithmen zur Artefaktkorrektur und Klassifikation kognitiver und emotionaler Zustände ebnet den Weg für den nicht-klinischen Einsatz von BCIs [1], [52], [79], [85], [92]–[94]. Beim klassischen aktiven BCI-Ansatz konzentrieren sich die verwendeten maschinellen Lernalgorithmen hauptsächlich darauf, die Anzahl der pro Minute übertragenen Bits (Informationsübertragungsrate) und so die erfolgreichen Klassifikationsraten der extrahierten Gehirnmuster zu steigern [95].

»Beim impliziten BCI-Ansatz müssen die Nutzer*innen mentale Aktionen nicht aktiv ausführen, um Gehirnmuster zu erzeugen, die in Maschinenaktionen übersetzt werden. Vielmehr dient deren Einsatz dazu, die Interaktion zwischen Mensch und autonom agierenden Maschinen zu verbessern.«

Beim impliziten BCI-Konzept steht nicht die Bit-Übertragungsrate aus den neurophysiologischen Signalen im Vordergrund, sondern vielmehr die Verbesserung der Interaktion zwischen Mensch und autonom agierenden Computern oder Maschinen. Bei diesem BCI-Ansatz müssen die Nutzer*innen keine mentalen Aktionen aktiv ausführen, um Gehirnmuster zu erzeugen, die in Computer- bzw. Maschinenaktionen übersetzt werden. Im Gegenteil, das implizite BCI-Konzept wird als kontinuierlicher Gehirnmonitoring-Prozess verstanden, der dazu dient, kognitive oder emotional-affektive Prozesse der Nutzer*innen in Echtzeit zu berücksichtigen [85], [93], [96]–[100]. Dies bildet die Grundlage für verbesserte computergestützte Nutzermodelle in einem adaptiven Mensch-Maschine-Regelkreis.

Open-loop EEG oder fNIRS-basierte passive BCIs zum Monitoring psychologischer Prozesse wie Engagement, Benutzerabsicht, selektive Aufmerksamkeit und Arbeitsbelastung bei Studierenden, Fahrenden, Pilot*innen oder Fluglotsen wurden bereits eingeführt [32], [38], [101]–[108]. Affektive Reaktionen wie Valenz und Erregung sind eine weitere Quelle von Benutzerinformationen, die als möglicher Input für adaptive Systeme dienen [1], [85], [92]–[94], [109], [110]. In einem *geschlossenen Mensch-Computer-Interaktionsparadigma* bereichern diese Informationen ein Benutzermodell, um nicht nur einen konkreten Befehl, sondern auch eine adäquate Systemanpassung an die Präferenzen, Fähigkeiten und Fertigkeiten der Benutzer*innen zu ermöglichen. So lassen sich die neurophysiologischen Signale im Sinne einer kontinuierlichen Darstellung des Zustands von einzelnen Benutzer*innen interpretieren. Mithilfe dieses Nutzermodells werden Informationen über psychologische Prozesse wie Kognition, Emotion und Motivation repräsentiert. In einem Regelkreis dient das geschätzte Nutzermodell als Eingabevariable, um das Ziel der Nutzerinteraktion und bestimmte Nutzerbedürfnisse durch intelligente Systemanpassung optimal zu unterstützen. Diese Entwicklungen ermöglichen symbiotische Mensch-Maschine-

Interaktionen, die dazu beitragen, neue technologische Lösungen an der Schnittstelle von Neurowissenschaften und Technologie zu beflügeln – es ergibt sich ein völlig neues Forschungsfeld: »Neuro-adaptive Technologien«.

In Kapitel 3 werden mögliche Szenarien von neuro-adaptiven Assistenzsystemen skizziert. Die nachfolgende Abbildung fasst die wesentlichen technischen Komponenten eines neuro-adaptiven Systems zusammen.

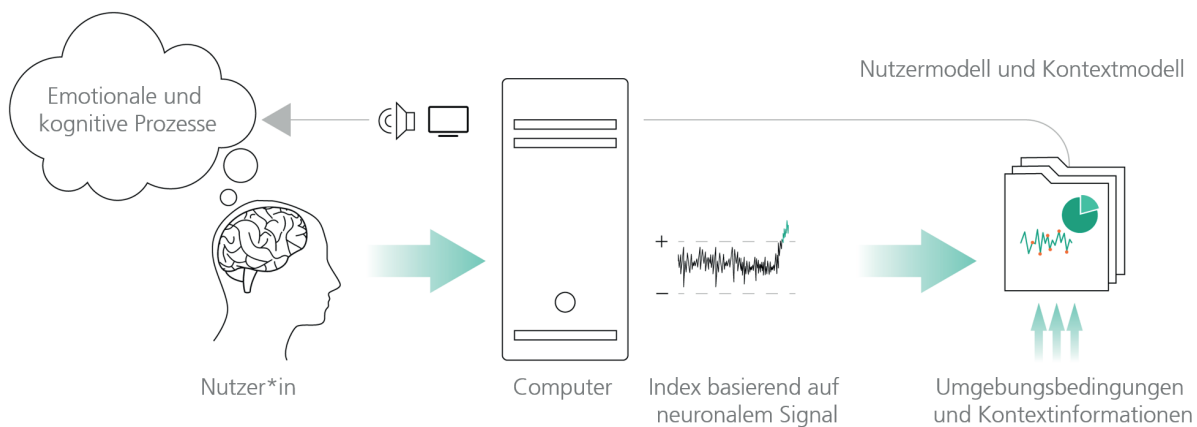


Abbildung 10: Der Unterschied zum klassischen Brain-Computer-Interface-Loop ist, dass hier noch ein Nutzermodell und Kontextmodell integriert ist⁸.

8 Definition in Anlehnung an: Laurens Krol et al. 2020 J. Neural Eng. 17 012001 [98].



Bei neuro-adaptiven Systemen handelt es sich um intelligente technische Systeme, die in einem Mensch-Technik-Regelkreis neurophysiologische Echtzeitmaße erfassen, daraus mentale Nutzerzustände interpretieren und ihr Systemverhalten entsprechend anpassen (adaptieren). Durch ihre individuelle Anpassungsfähigkeit können neuro-adaptive Technologien einen wesentlichen Beitrag für eine menschengerechte, effiziente und barrierefreie Technik leisten.



Vom Sensorsignal zur Bedeutung

Um aus einem Hirnsignal letztendlich eine Bedeutung und damit eine Anpassung des Systems an menschliches Verhalten zu ermöglichen, bedarf es einiger wichtiger Schritte.

Mithilfe eines EEG- oder fNIRS-Systems ist es möglich, das Signal – hier in Form einer Veränderung in der Hirnaktivität – zu messen. Die Interpretation der Aktivierungsmuster geschieht mithilfe von Algorithmen aus dem Bereich des Maschinellen Lernens. Bestimmte Zustände wie unterschiedliche Aufmerksamkeits- und Konzentrationslevel, die aktuelle Leistungsfähigkeit oder das emotionale Befinden eines Menschen kann somit aus den neuronalen Aktivitätsmustern dekodiert werden und dem System (z. B. einem Computer oder einer Maschine) als Feedback übermittelt werden.

Als Folge kann das System adäquat auf einzelne Nutzer*innen reagieren. Es lernt somit von den Menschen, welche Parameter zu einer optimalen Interaktion führen und kann sich an die Fähigkeiten und Bedürfnisse der Nutzer*innen anpassen. Somit ermöglichen implizite BCIs eine direkte Kommunikation zwischen Mensch und System, ohne speziellen Aufwand vonseiten der Nutzer*innen. Dies erleichtert und verbessert die Mensch-Technik-Interaktion und ermöglicht es, die zu erledigende Aufgabe mit der Unterstützung eines technischen adaptiven Systems optimal auszuführen.



Brain-Computer-Interfaces für eine implizite Nutzerzustandserkennung

Führt man sich das Anwendungsbeispiel des (teil-)autonomen Fahrens vor Augen, wird einem bewusst, dass das technische System in der Lage sein sollte, auf spontane Änderungen der Leistungsfähigkeit oder der mentalen Beanspruchung der Benutzer*innen möglichst in Echtzeit zu reagieren und diese zu adaptieren. Hierbei steuert die Person nicht willentlich eine bestimmte Aktion an, sondern reagiert instinktiv, z. B. auf bestimmte Gefahrensituationen im Straßenverkehr oder ermüdet unwissentlich nach einer bestimmten Dauer der Anwendung. Diese Änderungen in der Aufmerksamkeit und in der Leistungsfähigkeit der Person sollten von einem technischen System erkannt und darauf reagiert werden. Es wird eine Schnittstelle benötigt zwischen dem mentalen Zustand der Benutzerin oder des Benutzers und dem technischen System, das in diesem Fall, aufgrund der spontanen Verhaltensänderungen, durch ein implizites BCI verwirklicht wird. Die an das technische System weitergegebenen Informationen zum Nutzerzustand erlauben die Anpassung der internen Funktionen an die aktuelle Situation. Beispielsweise, indem das System eine neue Strategie in der Prozessumsetzung wählt oder die eigenen Parameter wie etwa die Geschwindigkeit anpasst. Des Weiteren können implizite BCI-Anwendungen bei interaktiven Lernprogrammen sinnvoll genutzt werden, in denen das Tempo und der Schwierigkeitsgrad der zu lernenden Aufgabe an die aktuelle Leistungsfähigkeit angeglichen wird. Das Ziel der Anwendung impliziter BCIs ist es, auf die Bedürfnisse und Fähigkeiten der jeweiligen Nutzer*innen einzugehen. Somit erlaubt es eine verbesserte Interaktion zwischen Menschen und Maschinen und die bestmögliche Unterstützung eines externen technischen Systems bei der Erfüllung bestimmter Aufgaben.

Hybride Brain-Computer-Interface-Anwendungen für eine verbesserte Zustandserkennung

Hybride Systeme kombinieren ein BCI entweder mit einem weiteren BCI oder einem weiteren System zur Messung peripher-physiologischer Signale (z. B. EKG oder EDA). Dies erlaubt somit die Verarbeitung mehrerer verschiedener Signale. Die neurophysiologischen Maße (EEG und fNIRS) können somit mit weiteren peripher-physiologischen Signalen (z. B. der Herzaktivität oder der Hautleitfähigkeit) ergänzt werden. Dadurch ist es möglich, die Vorteile mehrerer Systeme zu nutzen, um eine bessere Abschätzung zu erhalten und damit auch die Anwendung individueller auf einzelne Nutzer*innen zuzuschneiden. Das BCI kann so eine deutlich verbesserte Leistung und geringere Rate an falsch-positiven Ergebnissen erreichen (d. h. das BCI hat ein Ereignis erkannt, obwohl die jeweiligen Benutzer*innen im Ruhezustand waren). Die Idee ist vergleichbar mit der eines hybriden Fahrzeugs, bei dem zwei verschiedene Motoren kombiniert werden, um bestimmte Eigenschaften des Fahrzeugs zu verbessern.

3 EINSATZ IN DER PRAXIS

3.1 Einsatz von feinfühliger Technik zur Gestaltung von menschenzentrierter Technik

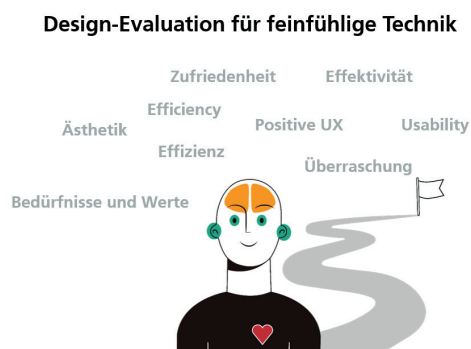
Wie kommt ein neues Produkt bei den Kund*innen an? Bewirkt die letzte Designveränderung eine verbesserte User Experience? Welche Emotionen werden bei der Wahrnehmung neuer Produkte und bei Interaktionen mit den Kund*innen ausgelöst? Diese Fragen spielen in praxisnahen Anwendungen – besonders bei der Produktentwicklung und -evaluation eine große Rolle.

Die Methoden und Ansätze der Neuroergonomie ermöglichen eine objektive und wissenschaftlich fundierte Untersuchung von Wahrnehmungs- und Evaluationsprozessen – sowohl bei der Interaktion von Software als auch Hardware mit den Nutzer*innen. Die gewonnenen Informationen können für folgende Aspekte verwendet werden:

- Nachhaltige Verbesserung von Produkten, Services und Arbeitsabläufen,
- Entwicklung von empirisch fundierten Design-Guidelines,
- Potenzialanalysen,
- Konzept- und Szenarienentwicklung, z. B. für adaptive Assistenzsysteme

Bei der Produkt- und Technikentwicklung sowie Evaluation spielt Usability, aber vor allem auch eine positive User Experience (UX) für die Attraktivität und somit die Kauf- und Empfehlungswahrscheinlichkeit eines Produkts eine entscheidende Rolle (Abbildung 11). Dies trifft sowohl auf kommerzielle Produkte als auch auf Technologien in der Arbeitswelt zu, bei denen eine optimale Mensch-Technik-Interaktion mit geringer Fehlerrate und Zeiteffizienz entscheidend ist.

Abbildung 11: Auswahl von psychologischen Konstrukten und Faktoren, die die Bewertung eines Produkts oder eines Services beeinflussen. Dabei werden Nutzer*innen im Sinne eines menschenzentrierten Ansatzes für die Entwicklung von feinfühli-ger Technik in den Mittelpunkt gestellt.



Jedoch birgt die direkte Befragung von möglichen Endnutzer*innen bei der Produktentwicklung oder bei der Evaluation die Gefahr einer potenziellen Verzerrung, beispielsweise aufgrund sozialer Erwünschtheit oder Selektionsprozessen bei der Verbalisierung [13]–[15].

Soziale Erwünschtheit beschreibt die Tendenz, allgemein in sozialen Situationen entsprechend den Erwartungen anderer zu antworten oder sich zu verhalten. Somit wird auf eine Frage oder Bewertung eines Produkts nicht mit der persönlich zutreffenden Antwort reagiert, sondern in Einklang mit sozialen Normen oder Erwartungen [111]. Neurowissenschaftliche Methoden, die aus Gehirn- und Körpersignalen implizite affektive Reaktionen ableiten, erlauben somit Bewertungen, die nicht verbalisiert werden, zu erfassen und das emotionale Erleben objektiver zu untersuchen.



So lassen sich unter anderem die Methoden der kognitiven Neurowissenschaft und Positiven Psychologie in einem multimodalen Ansatz kombinieren [112]. Die Ansätze und Methoden neuroergonomischer Forschung erlauben uns somit folgende praxisnahe Anwendungen feinfühler Technik (im Sinne der Messung von kognitiven Prozessen und emotionalen Erlebnissen) in verschiedenen Branchen:

- Objektive Produktevaluation und Designzyklen mittels eines (multimodalen) Methodenkastens der Neuroergonomie und positiven UX
- Zug geschnittene Neuro-User tests
- Schulungen zu Methoden und Guidelines, wann und wie Neuroergonomie zu nutzen ist
- Empirisch belegte Handlungsempfehlungen und Entscheidungshilfen
- Potenzialanalysen und Konzeptentwicklung neuer Innovationen der Neuroergonomie

Im Folgenden zeigen wir anhand von zwei Anwendungsbeispielen, wie neuroergonomische Methoden in der Praxis eingesetzt werden können, und welches Potenzial sich dadurch für die Technikgestaltung und Produktevaluation ergibt.

3.1.1 Optimierung der 25sten Stunde

Motivation und Herausforderung: Selbstfahrende Autos der Zukunft bieten völlig neue Möglichkeiten der Nutzung von Zeit während einer Autofahrt. Während uns das Fahrzeug selbstständig zu unserem gewünschten Ziel fährt, können wir die freie Zeit im Auto nutzen, um zu

schlafen, zu essen, zu lesen oder auch zu arbeiten. Gemeinsam mit der Audi AG haben wir im Rahmen des Projekts »25. Stunde«⁹ nach den idealen Arbeitsbedingungen im selbstfahrenden Auto geforscht. Dabei haben uns vor allem folgende Fragen besonders interessiert:

- Wie könnte ein Auto aussehen, das jedem Menschen eine optimal auf ihn angepasste Arbeitsumgebung bietet?
- Kann uns das Auto in Zukunft dabei unterstützen, konzentriert und produktiv zu arbeiten?

Methodik: Zur Beantwortung dieser Fragen haben wir im Rahmen eines Laborexperiments gemeinsam mit dem Autohersteller einen Simulator für vollautomatisiertes Fahren – mit variablem Innenraum und ohne Lenkrad – am Fraunhofer IAO aufgebaut (siehe auch nachfolgende Abbildung 12).




Abbildung 12: Aufbau des stationären Fahrsimulators
(© Audi AG)¹⁰.

Der Aufbau ermöglichte die variable Gestaltung des Innenraums, wie Umgebungslicht und Geräuschkulisse im Innen- und Außenraum. Die Fensterscheiben ließen sich dimmen und über Displays konnten digitale Störreize erzeugt werden. Um herauszufinden, wie sich unterschiedliche Konfigurationen des Fahrzeuginnenraums auf die Konzentrationsanstrengung, Leistungsfähigkeit und kognitive Beanspruchung eines Menschen bei der Bearbeitung konzentrations-

⁹ <https://www.theverge.com/2017/7/10/15947784/audi-25th-hour-autonomous-car-driving-work-time>

¹⁰ Grafik entnommen aus Pollmann et al. 2019 CHI '19 [112].

fordernder Aufgaben auswirkt, haben wir eine neuroergonomische Studie mit insgesamt 30 Teilnehmer*innen durchgeführt. Deren detaillierte Ergebnisse wurden im Rahmen einer wissenschaftlichen Publikation veröffentlicht und können von interessierten Leser*innen unter [112] nachgeschlagen werden. Die nachfolgende Abbildung 13 veranschaulicht die drei getesteten Konfigurationen eines Autoinnenraums (basierend auf Beleuchtung, visueller Stimulation und Sound).




Abbildung 13: Die Abbildung zeigt die drei unterschiedlich getesteten Innenraumkonfigurationen. Links: Beleuchtungskonzept für die freizeitorientierte Konfiguration des prototypischen selbstfahrenden Autos – lineares, dunkleres Licht mit wenig Blauanteilen (© Audi AG). Mitte: Die normale Konfiguration basiert auf der aktuellen Erfahrung einer Autofahrt ohne spezifische Beleuchtung, mit monotonem Verkehrslärm aus der Umgebung und wenigen visuellen Ablenkungen, die auf den interaktiven Fenstern angezeigt werden (© Audi AG). Rechts: Konzentrationsfokussierte Innenraumkonfiguration des selbstfahrenden Auto-Prototyps – großflächiges, helles Licht mit hohen Blauanteilen und unscharfen Fensterscheiben (© Audi AG)¹¹.

Während der simulierten Fahrt mussten die Teilnehmer*innen visuelle und auditorische Konzentrationsaufgaben lösen. In diesem Zeitraum haben wir die Konzentration, Leistungsfähigkeit und kognitive Belastung der Personen mit subjektiven, verhaltensbezogenen Messungen und Messungen der Gehirnaktivität (Elektroenzephalographie, EEG) bewertet.

Ergebnisse: Unsere Ergebnisse zeigen, dass eine Konfiguration mit großflächigem, hellem Licht mit hohem Blauanteil und reduzierten visuellen und auditiven Reizen mit erhöhter Leistung, Qualität, Effizienz, Konzentration und geringerer kognitiver Arbeitsbelastung einhergeht. Erhöhte visuelle und auditive Reize, gepaart mit linearem, dunklerem Licht mit sehr wenigen Blauanteilen, führten zu geringerer Leistung, subjektiver Konzentration und höherer kognitiver Arbeitsbelastung. Die Ergebnisse unterschieden sich aber nicht von einer normalen Fahrzeugkonfiguration. Unser multimethodischer Ansatz der neuroergonomischen Forschung zeigt daher mögliche Fahrzeuginnenraumkonfigurationen für einen idealen Arbeitsplatz. Das Gehirn wird in einem Interieur ohne störende Einflüsse weniger beansprucht, wie z. B. bei gedimmten Scheiben, optimierten Lichteinstellungen und Unterdrückung digitaler Nachrichten.

3.1.2 Affective Computing – Emotionserkennung während der Interaktion

Motivation und Herausforderung: Eine positive Evaluation von Produkten oder Services wirkt sich positiv auf den Kaufwillen und die Kundenzufriedenheit aus. Dabei können die Rückmeldungen von potenziellen Endnutzer*innen in den verschiedenen Phasen der Produktentwick-

¹¹ Die Grafiken wurden aus Pollmann et al. 2019 CHI '19 [112] entnommen.

lung, z. B. bei der Konzeption, Gestaltung oder Überarbeitung eines Produkts eingesetzt werden. Unter anderem erlauben User-Tests auch den Vergleich von verschiedenen Versionen eines Produkts (z. B. einer Webapplikation). In diesen User-Tests mit potenziellen Kund*innen können sowohl Usability (Benutzerfreundlichkeit) als auch Freude und positive Erfahrung bei der Nutzung erhoben werden. Besonders die Kombination aus subjektiven mit objektiven Methoden, z. B. neuro- und peripher-physiologische Messungen und Fragebögen, ist hierbei vielversprechend. Die Herausforderung des Anwendungsbeispiels ist es, eine robuste und aussagekräftige Methode zu entwickeln, um Emotionen und die emotionale Evaluation während einer natürlichen Interaktion mit Produkten (z. B. bei der Bedienung eines Smartphones) zu erkennen.



Affective Computing, auch Emotionale Künstliche Intelligenz (KI) oder Emotion Artificial Intelligence (AI) genannt, ist ein Forschungsgebiet innerhalb des Cognitive Computing und der Künstlichen Intelligenz (KI). Es beschäftigt sich mit dem Entwickeln von Systemen, die aus Daten, z. B. aus Gesichtsausdrücken, Stimmen, Körper- und Gehirnsignalen erlernen, Emotionen zu erkennen, zu interpretieren und teilweise sogar auszudrücken [113].

Methodik: Wir haben einen experimentellen Methodenansatz entwickelt, der subjektive und objektive Messungen kombiniert, um zu untersuchen, ob positive und negative emotionale Erfahrungen auf der Grundlage der Aktivierungsmuster des zentralen und peripheren Nervensystems unterschieden werden können. Hierfür haben wir wissenschaftlich fundierte und State-of-the-Art-Erfassungsmethoden verwendet, um Emotionen während der Techniknutzung zu erheben. Für die objektiven neuro- und peripher-physiologischen Messungen wurden EEG, EKG und EDA eingesetzt. Zudem wurden Emotionen anhand von Aktivierungen der Gesichtsmuskulatur mittels eines kamerabasierten Systems und Maschinellen Lernalgorithmen der Gesichtsverarbeitungssoftware AFFDEX ([114], [115]) entschlüsselt (sogenanntes Facial Decoding). Nach jedem Interaktionsszenario wurden verschiedene Skalen und Fragebögen, die die positiven Nutzererfahrungen, unter anderem (a) die ästhetische Bewertung, (b) Überraschungserlebnisse und (c) Erfüllung individueller Bedürfnisse sowie Benutzerfreundlichkeit untersuchen, eingesetzt. Dies dient zur weiteren Validierung, Annotation und Ergänzung der gemessenen Gehirn- und Körpersignale. Eine Übersicht über den experimentellen Aufbau der multimodalen Emotionserkennung in einem neuroergonomisch-gestützten Nutzertest zeigt Abbildung 14.


Dieser Ansatz wurde im Rahmen einer empirischen Studie mit 30 Teilnehmer*innen untersucht. Dabei wurden verschiedene Versionen von Smartphone-Apps, die sich hinsichtlich ihrer Usability und positiven UX unterschieden, evaluiert.

Als Interaktionsszenarien wurden klassische Aktionen bei der Smartphone-Nutzung ausgewählt (z. B. das Einstellen eines Kalendertermins oder das Ändern des Passworts).

Ergebnisse: Die Analysen der erfassten physiologischen und subjektiven Daten wurden mithilfe von statistischen Verfahren und Methoden des Maschinellen Lernens durchgeführt. Dabei haben wir verschiedene ML-Algorithmen des überwachten Lernens für die einzelnen Modalitäten verglichen. Es eignen sich sowohl klassische ML-Methoden, die eine Merkmalsextraktion durch Expert*innen erfordern, als auch ML-Methoden des tiefen Lernens. Unsere Ergebnisse zeigten, dass wir anhand der erhobenen Gehirn- und Körpersignale positive Nutzungserlebnisse mit guter Benutzerfreundlichkeit und schlechte Nutzungserlebnisse mit schlechter Benutzerfreundlichkeit mit einer hohen Genauigkeit voneinander unterscheiden konnten: Für die logistische Regression konnte eine durchschnittliche Genauigkeit von 97,9 Prozent (Standardabweichung von 3,9 Prozent) und für den Random-Forest-Klassifikator eine durchschnittliche Genauigkeit von 99,6 Prozent (Standardabweichung von 1,0 Prozent) erzielt werden. Besonders vielversprechend war die Unterscheidung von positiven und negativen Nutzungserlebnissen anhand der kamerabasierten Emotionserkennung im Gesicht mittels des Random-Forest-Algorithmus. Die Funktion der Merkmalsgewichtung des Algorithmus zeigte, dass besonders die Mundpartie informativ für die Unterscheidung von positiven und negativen Emotionen ist. Die genauen Studienergebnisse werden in Kürze bei einer wissenschaftlichen Zeitschrift zur Veröffentlichung eingereicht. Das Projekt zeigt, dass wir positive und negative Emotionen während der Techniknutzung erfassen und voneinander unterscheiden können. Dies kann – anhand von neuro- und peripher-physiologischen Mustern als auch in der Analyse der Gesichtsbewegungen geschehen. Die Ergebnisse sind valide, zuverlässig und wissenschaftlich auf höchstem Niveau.

Durch Erkenntnisse aus Emotionserkennungsstudien können Hersteller wichtige Erkenntnisse über die Attraktivität, Zufriedenheit und Akzeptanz ihres Produkts erhalten, ohne sich dabei nur auf die subjektiven Aussagen der Nutzer*innen verlassen zu müssen. So liefert unser multi-methodischer Ansatz einen umfassenderen Einblick und Verständnis in die Erlebniswelt von Nutzer*innen im Umgang mit technischen Produkten

Abbildung 14: In einem multi-modalen neurowissenschaftlichen Ansatz wurden die Emotionen von Nutzer*innen während der Interaktion mit einem alltäglichen Elektronikgerät (hier einem Smartphone) untersucht. Dafür wurden EEG, EKG, EDA und Gesichtsemotionserkennung für die emotionale Evaluationserkennung kombiniert.



3.2 Feinfühlige Technik für Echtzeitanwendungen

Die Methoden der Neuroergonomie und der angewandten Neurowissenschaft lassen sich nicht nur zur Evaluation von Produkten und Services einsetzen, sondern ermöglichen auch die Entwicklung von zukünftigen neuro-adaptiven Assistenzsystemen auf Basis einer BCI-Technologie. Somit kann eine Echtzeitinteraktion und -anpassung ermöglicht und so die Gestaltung einer feinfühligem empathischen Technik Realität werden. Im Folgenden zeigen wir mögliche Anwendungsgebiete, Methodik und Forschungs- und Entwicklungsergebnisse, an denen wir arbeiten, anhand konkreter Szenarien.

3.2.1 Physiologisches Monitoring für die Fahrerzustandserkennung

Motivation und Herausforderung: Wir können davon ausgehen, dass ein zunehmender Automatisierungsgrad den Stress und die mentale Belastung von Fahrer*innen reduziert – sodass mehr Zeit für nicht fahrbezogene Aufgaben bleibt. Es ist jedoch zu erwarten, dass auch in (teil-) autonomen Fahrzeugen das Fahren weiterhin kognitiv und emotional anspruchsvoll sein wird. So werden auch in Zukunft hohe Aufmerksamkeitsressourcen der Fahrer*innen beansprucht, um die Kontrolle zu übernehmen und verschiedene Fahrsituationen zu manövrieren. Mangelnde Aufmerksamkeit gilt dabei als die Hauptursache für Autounfälle. Zum Beispiel führt das Fahren unter Stresssituationen, wie bei unterschiedlichen Witterungsbedingungen oder bei gleichzeitiger Ausführung einer Nebenaufgabe zu einer erhöhten Aufmerksamkeit und ist weiterhin mit einem höheren Unfallrisiko korreliert. Zudem sind abgelenkte, schläfrige, gestresste oder

emotional aufgewühlte Fahrer*innen in ihrer Reaktions- und Urteilsfähigkeit teilweise erheblich eingeschränkt. Angesichts dieser Herausforderungen ist die Erkennung des Fahrerzustands im Fahrzeug ein aufstrebender und wichtiger Forschungszweig im Automobilbereich geworden. Die Mensch-Maschine-Schnittstelle spielt hier eine entscheidende Rolle, um unerwartete Ereignisse zu bewältigen und einen sicheren und reibungslosen Übergang der Steuerung zu gewährleisten. Zuverlässige Methoden der Fahrerzustandserkennung sind daher von hoher Bedeutung für die Erhöhung der Verkehrssicherheit. Zugleich tragen sie zur Steigerung der Akzeptanz gegenüber (teil-)autonomen Fahrzeugen bei. Der Forschungsbedarf spiegelt sich in der steigenden Anzahl von Studien wider, die untersuchen, wie psychische Belastungen (mentaler Stress bzw. mentale Belastung des Arbeitsgedächtnisses, siehe auch Kapitel 2 für eine detaillierte Beschreibung) erkannt werden können und wie das Wissen über Belastungszustände von Fahrer*innen genutzt werden kann.

Methodik: Mentaler Stress bzw. mentale Belastung sind Konstrukte, die subjektive Reaktionen auf äußere Reize beschreiben. Es kann davon ausgegangen werden, dass Stress eine Folge von hoher mentaler Arbeitsbelastung ist. Im Kontext der Autofahrt wird zwischen externen Reizen unterschieden, die a) aus der Fahraufgabe und b) aus nicht fahrbezogenen Aufgaben (NFA) resultieren. Eine Kombination aus anspruchsvollen Fahraufgaben und anspruchsvollen NFA führt zu einer hohen mentalen Arbeitsbelastung und ist ein typischer Ansatz, um Stress bei Fahrer*innen zu induzieren. Unser Ansatz, um auf die mentale Belastung zu schließen, basiert auf der Prämisse, dass (neuro-)physiologische Signale wie Atmung, Gehirnaktivität oder Herzfrequenzaktivität mit der mentalen Arbeitsbelastung der Person korrelieren. Eine bislang etablierte Methode zur impliziten Erkennung von psychischen Stressereignissen ist die Messung der Modulationen des Herzfrequenzsignals (abgeleitet über die Elektrokardiographie, siehe auch Kapitel 2 für eine detaillierte Beschreibung). Eine wesentliche Herausforderung ist die Evaluation der Gebrauchstauglichkeit von Maschinellen Lernverfahren zur Klassifizierung der aufgezeichneten EKG-Signale und damit zur genauen Erkennung mentaler Stresslevel während der Fahrsituation. Obwohl klassische Maschinelle Lernmodelle (siehe auch Kapitel 2.2.3 für einen detaillierten Überblick) die Machbarkeit der Klassifizierung von psychischem Stress bewiesen haben, haben sie ernsthafte Einschränkungen für den praxisnahen Einsatz: Die Ansätze benötigen Domänenwissen, um sinnvolle Merkmale zu extrahieren. Normalerweise werden in solchen Ansätzen vordefinierte Zeitfenster gewählt und die Merkmale innerhalb dieser Fenster berechnet. Da die Erkennung von mentalem Stress auf Variationen der Herzratenvariabilität basiert, beträgt die Fensterlänge üblicherweise bis zu mehreren Minuten. Daher können Schätzungen der psychischen Belastung nur mit mehreren Minuten Verzögerung vorgenommen werden, was für die Erkennung der Belastung der Fahrer*innen nicht akzeptabel ist. So zeigen mögliche Deep-Learning-Techniken großes Potenzial, um diese Probleme anzugehen. Dazu haben wir eine empirische Studie im Fahrsimulator (Abbildung 15) des Fraunhofer IAO mit insgesamt neun Teilnehmer*innen durchgeführt.

Abbildung 15: Fahrsimulator im Vehicle Interaction Lab am Fraunhofer IAO¹². Das Fahrzeug-Mock-Up besteht aus einem Porsche Macan und wird mit der SILAB-Fahrsimulator-Software betrieben.



Ergebnisse: In der durchgeführten empirischen Studie waren wir daran interessiert, Methoden des Maschinellen Lernens anzuwenden, um mentalen Stress aus einem mobilen physiologischen Sensor zu erkennen, der EKG-Signale bei Fahrer*innen unter verschiedenen Umgebungsstressniveaus aufzeichnet. Die stressigen Ereignisse standen im Zusammenhang mit der zwischen selbstfahrendem und automatisiertem Fahren wechselnden Fahraufgabe mit unterschiedlicher Komplexität. So war die Datenerfassung eingebettet in ein realistisches Fahrscenario mit einer sogenannten »Cover Story« für die Teilnehmer*innen. Ihre Aufgabe war es, so schnell und sicher wie möglich zu fahren, um einen Flug zu erreichen. Diese Aufgabe spiegelte eine anspruchsvolle Fahraufgabe wider. Ein Teil der Fahrzeit war im automatisierten Fahren und damit weniger anspruchsvoll. Während der manuellen und auch während der automatisierten Fahraufgaben führten die Teilnehmer*innen verschiedene Sekundäraufgaben auf einem Tablet durch – z. B. Lesen und Erinnerungen von E-Mails oder eine psychologisch standardisierte n-back-Aufgabe.

Das Ziel war es aus den erhobenen EKG-Daten einen Deep-Learning-Ansatz (engl. convolutional neural network (CNN), siehe auch Kapitel 2 für eine detailliertere Beschreibung) mit klassischen Machine-Learning-Ansätzen für ein Drei-Klassen-Problem zur Klassifizierung von psychischem Stress – niedriger, mittlerer und hoher Stress – zu vergleichen. Dabei wurden sehr kurze Zeitintervalle (< 10-Sekunden-Intervalle) der EKG-Signale gewählt. Wir stellten die Hypothese auf, dass die Leistung konventioneller Maschineller Lernmodelle bei der Verwendung sehr kurzer Zeitintervalle begrenzt ist, während die CNN-Architektur in der Lage ist, nichtlineare Informatio-

12 <https://www.hci.iao.fraunhofer.de/de/ueber-uns/labore/vehicle-interaction-lab.html>

nen (ohne manuelle Merkmalsextraktion) zur Leistungsverbesserung in sehr kurzen EKG-Zeitssegmenten zu erkunden. In unserem Vergleich haben wir eine auf EKG-Signale optimierte CNN-Architektur [56] gegen drei klassische Machine-Learning-Ansätze (Support-Vektor-Methode, logistische Regression und Ensemble-Methode) antreten lassen. Im Durchschnitt (Mittelwert über alle Teilnehmer*innen) erreichte die CNN-Architektur eine Genauigkeit von 68,34 Prozent (Standardabweichung von 4,23 Prozent), die Support-Vektor Methode 44,12 Prozent (Standardabweichung von 8,98 Prozent), die Logistische Regression 43,48 Prozent (Standardabweichung von 10,56 Prozent) und die Ensemble-Methode nur 38,94 Prozent (Standardabweichung von 11,95 Prozent). Die Ergebnisse zeigen eine Verbesserung im Durchschnitt von ca. 24 Prozent der Deep-Learning-Technik gegenüber den anderen Machine-Learning-Ansätzen. Eine rein zufällige Klassifikation läge in diesem Drei-Klassen-Klassifikationsproblem bei etwa 33 Prozent. In den Ergebnissen ist eine wesentlich geringere Varianz in der Klassifikation der einzelnen Teilnehmer*innen bei der CNN-Architektur zu beobachten. Die Fähigkeit, sehr kurze EKG-Daten-segmente robust zu klassifizieren, ist für die Echtzeitklassifizierung wichtig. In Zukunft planen wir, diese Fähigkeit der CNN-Architektur für die Echtzeiterkennung von Fahrerzuständen zu erproben. Die Ergebnisse aus dieser Studie werden weiterhin in einer wissenschaftlichen Publikation nach Erscheinung dieser Studie veröffentlicht.

3.2.2 Neuro-adaptive Lernassistenten und -programme

Motivation und Herausforderung: Die traditionellen Industrien, gerade in Deutschland, befinden sich derzeit in einem revolutionären Umbruch. Arbeitstätigkeiten werden zunehmend automatisiert. Gleichzeitig werden durch Digitalisierung und Methoden der künstlichen Intelligenz die Anforderungen an die Mitarbeiter*innen immer komplexer. Damit Mitarbeiter*innen sowie Unternehmen von den Entwicklungen gleichermaßen profitieren, spielen die Kompetenzen der Betroffenen eine entscheidende Rolle. So sind der kontinuierliche Wissens- und Kompetenzerwerb sowie dessen Selbstverständnis die Grundvoraussetzung, um die Erwerbsfähigkeit der Menschen in der immer komplexer werdenden Arbeitswelt nachhaltig zu sichern. Es besteht ein großer Bedarf, die betriebliche Weiterbildung, Umschulungen, Ausbildung und Einweisungen in neue Technologien und Abläufe effizienter zu gestalten. Insbesondere durch die hohe Entwicklungsgeschwindigkeit neuer Technologien, z. B. im Bereich der Informationstechnologie, KI-Methoden, Mobilität und Energieerzeugung, wird eine effiziente und effektive Anpassung der Mitarbeiter*innen an neue Gegebenheiten und Randbedingungen zunehmend zum Wettbewerbsvorteil.

Dabei stellt das Konzept des lebenslangen Lernens einen Schlüssel zum Erfolg dar. Von zentraler Bedeutung ist es, die individuellen Fähigkeiten und Bedürfnisse der Lernenden angemessen zu berücksichtigen. Gerade hier besteht großer Bedarf in der Anpassung der Lehrinhalte an die

Bewertung des Lernerfolgs und -fortschritts. So lassen sich einerseits Potenziale voll ausschöpfen, andererseits können mögliche Überforderungen vermieden werden. Idealerweise erfolgt dies kontinuierlich, nicht-intrusiv und objektiv, um Ablenkungen zu vermeiden und um eine personalisierte Lernerfahrung und Freude am Lernen zu ermöglichen.

Methodik: Adaptive Lernumgebungen und neuro-adaptive Lernassistenten bieten hierbei die Lösung. Mittels neurophysiologischen Messmethoden können kontinuierliche (neuro-)physiologische Beurteilungen mentaler Beanspruchungen, Aufmerksamkeitszustände und Lernprozesse ermöglicht werden, um auf dessen Basis Anpassungen und Optimierungen der Lehrstrategie und präsentierten Lerninhalte zu ermöglichen. Besonders von Interesse sind mentale Prozesse der exekutiven Funktionen der Lernenden, wie z. B. die Arbeitsgedächtnisleistung, mentale Beanspruchung und Impulskontrolle. Besonderes Potenzial für adaptive Lernumgebungen und -assistenten birgt die Kombination von neurophysiologischen Messmethoden mit immersiven Technologien wie Virtual Reality (VR). Somit können die Trainings- und Lernerfahrungen, u. a. in gamifizierten Ansätzen, angereichert werden. VR ermöglicht insbesondere eine realitätsnahe Darstellung von Trainingsobjekten, wie z. B. Maschinen und Anlagen für Trainingseinheiten in der Produktion oder einem virtuellen Torso bei chirurgischen Operationsübungen. Es erlaubt zudem die direkte räumliche Interaktion mit diesen virtuellen Objekten, was eine wichtige Lernkomponente darstellt. Dadurch können die Lernenden auf hoch realistische und sichere Weise Kenntnisse und praktische Fähigkeiten erwerben, ohne dass das Trainingsobjekt physisch verfügbar sein muss. Neben der größeren räumlichen und zeitlichen Flexibilität und der Kostenreduktion bietet die Kombination mit VR auch die Möglichkeit, potenziell gefährliche Arbeiten zu trainieren und Fehler und Konsequenzen plastisch sichtbar zu machen.

Abbildung 16: Illustratives Beispiel einer (neuro-)adaptiven Lernumgebung, die die kontinuierliche (neuro-)physiologische Evaluation mentaler Beanspruchungen und Lernprozesse ermöglicht, um auf dieser Basis Anpassungen und Optimierungen der präsentierten Lerninhalte zu ermöglichen.



Ergebnis: In verschiedenen Forschungs- und Industrieprojekten entwickeln wir (hybride) BCI-Anwendungen (z. B. EEG und fNIRS) und ML-Verfahren, die eine personalisierte und situationsgerechte Anpassung von Lerninhalten ermöglichen. Die Anpassung kann sich dabei auf den Schwierigkeitsgrad, die Granularität der Arbeitsschritte oder die Darstellung der Lerninhalte beziehen. Des Weiteren können diese Verfahren auch zukünftig für die Detektion von Konzentrationstiefs und zur Pausenempfehlung verwendet werden. Damit diese Szenarien Realität werden können, arbeiten wir in enger Kooperation mit weltweit führenden Herstellern neurophysiologischer Messsysteme, um sowohl Soft- als auch Hardware für den routinemäßigen Gebrauch weiterzuentwickeln.

3.2.3 MindTrain – Förderung mentaler Fitness

Motivation und Herausforderung: Moderne Arbeitsplätze sind zunehmend von digitaler Technik geprägt. Die ständige Erreichbarkeit und kontinuierliche Ablenkungen durch Smartphones, Apps und soziale Medien erschweren gezielte Phasen des konzentrierten Arbeitens oder der bewussten Entspannung und Erholung. Neuro-adaptive Assistenzsysteme erlauben a) die Erkennung augenblicklicher mentaler Zustände und b) die direkte Rückmeldung dieser Zustände über eine visuelle, auditive oder haptische Schnittstelle an einzelne Nutzer*innen. Daher eignen sie sich, um die Fähigkeit der bewussten Konzentration und Entspannung in einer Neurofeedback-Umgebung zu lernen und trainieren. Ziel ist es, die Kontrolle über mentale Zustände auch in einer reizüberfluteten Umgebung zu optimieren und somit das Wohlbefinden im täglichen Leben oder im Arbeitskontext zu fördern.

Methodik: Wir haben eine Anwendung namens MindTrain entwickelt, die Konzentrations- und Entspannungszustände identifiziert und mittels VR-basiertem Feedback die Kontrolle über die Zustände spielerisch fördert. Die gamifizierte Neurofeedback-Trainingsumgebung kombiniert das Konzept der impliziten Kontrolle mit einem mobilen EEG und mit einer interaktiven und immersiven VR-Umgebung zur Visualisierung des Feedbacks, siehe Abbildung 17. Sie erlaubt so den Anwender*innen, die Fähigkeit zu erlernen, ihre Gehirnaktivität freiwillig selbst zu regulieren. Sie lernen, Zustände der Entspannung und Konzentration bewusst hervorzurufen und erhalten in der virtuellen Realität über Umgebungs- und Spielparameter Feedback, wie gut es ihnen jeweils gelungen ist. Da hier ein mobiles EEG verwendet wird, das einfach einsetzbar und komfortabel ist, eignet sich MindTrain für den Einsatz im Alltag oder bei der Arbeit.

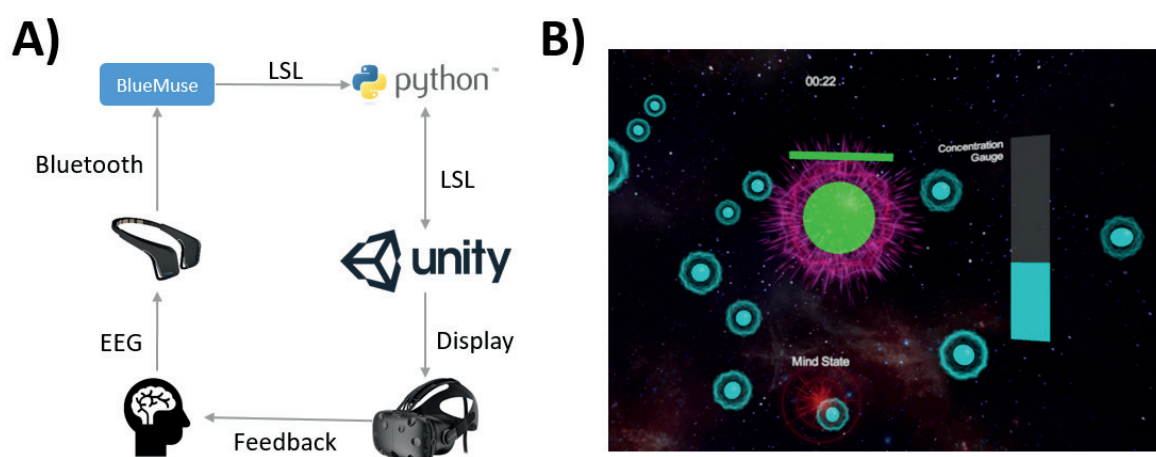


Abbildung 17: A) Übersicht über die verwendeten Komponenten, u. a. EEG und VR, der Neurofeedback-Trainingsumgebung MindTrain. B) Ausschnitt aus der Spielumgebung von MindTrain, die zur Förderung von Entspannung und Konzentration eingesetzt wird¹³.

Ergebnis: In einer empirischen Prototypenstudie haben wir untersucht, wie gut sich die entwickelte Anwendung MindTrain eignet, um gezielt Entspannungs- und Konzentrationszustände zu trainieren und das Wohlbefinden zu fördern. Die detaillierten Ergebnisse wurden im Rahmen einer wissenschaftlichen Publikation veröffentlicht, interessierte Leser*innen können sie unter [116] nachschlagen. Interessanterweise zeigten die Teilnehmenden unterschiedliche Kontrollfähigkeiten für den entspannten und konzentrierten Zustand. Das bedeutet, dass manche Personen besonders gut darin sind, sich zu entspannen, aber Schwierigkeiten haben, sich gezielt zu konzentrieren und vice versa. Unsere Ergebnisse zeigen, dass MindTrain eine vielversprechende neue Methode zur Regulierung von Entspannung und Konzentration ist. Durch den Einsatz eines mobilen EEG-Geräts weist MindTrain großes Potenzial für einen Transfer der Anwendung aus dem Labor in reale Kontexte auf. Sowohl im Arbeitskontext als auch im privaten Alltag kann eine neuro-adaptive VR-Umgebung spielerisch Konzentration fördern, um gezielte Aufmerksamkeit und Entspannung in reizüberfluteten Umgebungen zu trainieren. Das Training der eigenen mentalen Kontrolle und das »innerlich zur Ruhe kommen« können sich dabei positiv auf das subjektive Wohlbefinden und eine Stabilität in der eigenen kognitiven Leistungsfähigkeit auswirken.


3.2.4 Feinfühligke kollaborative Roboter

Motivation und Herausforderung: Autonom agierende Systeme können durch Maschinelles Lernen immer mehr Arbeitsprozesse unterstützen. Dies betrifft insbesondere die Mensch-Roboter-Kollaboration, wie zum Beispiel in der roboter-assistierte Medizintechnik oder auch bei

¹³ Die Grafik wurde aus Kosuru et al. 2019 MUC'19 [116] entnommen.

Industrierobotern für flexiblere, kollaborative Produktionsprozesse. Damit Roboter die komplexen Aufgaben lernen können, werden Methoden des verstärkenden Lernens (engl. reinforcement learning, (RL)) eingesetzt. Um eine ausreichende Menge Trainingsdaten für eine optimale Anpassung des Roboterhaltens an einen Menschen zur Verfügung zu stellen, sind sehr viele, sehr unterschiedliche Interaktionssituationen zwischen Mensch und Maschine notwendig. Dabei ist ein kontinuierliches Feedback (Kritik und Belohnung) in Bezug auf das erlernte Verhalten des Roboters wichtig, um Fehler im Verhalten sofort zu korrigieren und eine sichere Anpassung an den Menschen zu gewährleisten. State-of-the-Art-Ansätze des Reinforcement Learnings zeigen jedoch, dass das Training sehr zeitintensiv ist, da das Feedback nur im Anschluss an ein gelerntes Verhalten erfolgt. Hinzu kommt, dass die Formalisierung von Domänenwissen bei komplexen Aufgaben, wie z. B. der Navigation eines Instruments in der Chirurgie, schwierig und kostenintensiv ist, da hier zusätzlich Bewertungen der Expert*innen explizit gegeben werden müssen.

Methodik: Als mögliche Lösung dieses Problems zeigen implizite Brain-Computer-Interfaces ein besonderes Potenzial. Anhand dieser kann eine kontinuierliche Feedbackfunktion der Roboteraktionen (z. B. das Navigieren des Roboterarms) aus impliziten neurophysiologischen Reaktionen von Expert*innen generiert werden. Somit lassen sich spontane affektive Bewertungen (z. B., die Frustration der einzelnen Expert*innen bei einer fehlerhaften oder verbesserungswürdigen Aktion des Roboters) verwendet werden, um damit den Roboter zu trainieren. Dabei kann die emotional-affektive Bewertung des Roboterhaltens auf zwei unabhängigen Dimensionen durch ein BCI abgebildet werden: »Valenz« (positiv – negativ) und »Erregung« (engl. arousal, von ruhig bis erregt). Die Erfassung der Valenz-Dimension erfolgt über das EEG, wohingegen die Erregung mittels peripher-physiologischer Methoden der EDA und EKG gemessen werden. So ist eine Verbesserung des Roboterhaltens durch interaktives Reinforcement Learning, auf der Grundlage einer robusten Erkennung der affektiven Bewertungsreaktionen der Expert*innen, möglich. Der Vorteil dabei ist, dass sich ein BCI für jegliche Anwendungen in der Mensch-Roboter-Kollaboration nutzen lässt, in der das Abschätzen einer Bewertungsfunktion – in Form der Evaluation, ob eine gute oder schlechte Robotertätigkeit im Sinne des Menschen gemacht wurde – ressourcenaufwendig und komplex ist.



Ergebnis: Wir untersuchen in verschiedenen Forschungs- und Entwicklungsprojekten Potenzial und Anwendungsmöglichkeiten von emotional-affektiven Reaktionen bei der Mensch-Roboter-Kollaboration. Beispielsweise bei roboterassistierten chirurgischen Eingriffen oder bei roboter-gestützten Fertigungsprozessen in der Industrie. Die emotional-affektiven Reaktionen werden zur Bewertung und zum Training der Roboter verwendet. Das Ziel ist es, robuste neurophysiologische Korrelate und affektive Reaktionen durch Maschinelles Lernen zu identifizieren und ihre Eignung als Feedbackfunktion zum Trainieren des Roboters zu explorieren. Die erzielten Ergebnisse sollen eine implizite, intuitiv und unmittelbare Bewertung von Maschinen- und Roboter-verhalten durch Menschen ermöglichen und dabei die subjektive Angemessenheit und Akzeptanz berücksichtigen. Zukünftig kann eine solche Bewertungsfunktion für völlig neuartige interaktive Reinforcement-Learning-Ansätze genutzt werden, um das Roboterverhalten in einer Simulation menschenzentriert zu trainieren, um dann die erlernten Strategien auf reale Szenarien zu übertragen – Sim-to-Real-Transfer.

3.3 Qualitative Interviews

Um einen besseren Einblick in die Praxis des Einsatzes von feinfühlgiger Technik zu gewinnen, wurden sieben qualitative Interviews mit acht Personen durchgeführt. Die Expert*innen stammen aus unterschiedlichen Branchen – der Automobilbranche, Technologiebranche, Telekommunikation, Entwicklung von Neurotechnologien, und Maschinenbau – und beschäftigen sich in unterschiedlichen Graden mit dem Einsatz und der Entwicklung von feinfühlgiger Technik.

In den geführten Interviews interessierte uns nicht die akademische Sichtweise und die Frage »Was wäre, wenn?«, sondern die Meinung der Praktiker*innen. Wir wollten wissen, was die Unternehmen über mögliche Unterstützungen mittels Brain-Computer-Interfaces, Affective Computing oder Methoden der Neuroergonomie denken. Wo sind schon Projekte ins Leben gerufen, und was sind die größten Hemmnisse? Gibt es schon Erfolgsstorys? Ergeben sich neue Perspektiven durch den Einsatz von feinfühler Technik für die Entwicklung innovativer Technologien?

Anhand der vorgestellten Methoden und Technologien der Neuroergonomie, dem Affective Computing und Brain-Computer-Interfaces wurden zwei Einsatzmöglichkeiten im Detail mit den Expert*innen diskutiert und kritisch reflektiert. 1) Erhebung von (neuro-)physiologischen Daten zur Produktevaluation und 2) Einführung weiterer Anwendungen von feinfühler Technik durch die echtzeitfähige Erkennung kognitiver und emotional-affektiver Prozesse. Die vorgestellten Einsatzmöglichkeiten basieren im Einzelnen auf den Beschreibungen in Kapitel 3.

In allen Interviews mit den Expert*innen haben ethische Fragestellungen einen wichtigen Stellenwert eingenommen. Eine intensive Diskussion dieser Aspekte sowie eine Darstellung der relevanten Richtlinien zur ethisch korrekten Gestaltung von intelligenten Systemen, insbesondere in Bezug auf die Interaktion mit Kund*innen, finden sich in der Schwester-Studie »Kundenservice empathisch gestalten« [117]. Darüber hinaus gibt es aber auch noch weitere Aspekte, die für eine gute und praktikable Lösung durch den Einsatz einer feinfühler Technik berücksichtigt werden sollen. Grundlage für die geführten Interviews waren die folgenden Leitfragen:

- Persönliche Einstellung und Erfahrungen zu Künstlicher Intelligenz, Maschinellem Lernen, Neuroergonomie, Brain-Computer-Interfaces, Affective Computing und feinfühler Technik
- Welche Verfahren oder Anwendungen würden Sie gerne nutzen, um Technik zu optimieren, tun es aber nicht? Warum?
- An welchen Stellen gibt es noch ungenutztes Potenzial, das mit einer feinfühler Technik ausgeschöpft werden kann?
- Auf welche Daten greifen Sie zurück für Anpassungen/Individualisierungen?
- Welche Szenarien können Sie sich vorstellen, in denen es Sinn ergibt, mentale Prozesse zu berücksichtigen? Wo sehen Sie weitere Potenziale?
- Wo sehen Sie am meisten Potenzial für eine Optimierung von Technik auf Basis einer feinfühler Technik wie dem Brain-Computer-Interface oder Affective Computing? Wo sehen Sie weitere Potenziale?
- Diskussion von möglichen Use-Cases
- Diskussion von ethischen Fragestellungen

Wir haben versucht, die zehn Kernaussagen der Expert*innen zu kondensieren, die im Einzelnen in anonymisierter Form dargestellt werden.

Der Einsatz feinfühligler Technik erlaubt einen völlig neuen Ansatz im Bereich User Experience

Branche: Telekommunikation

Position im Unternehmen: User-Experience-Evaluation-Ingenieur

Dauer dieser Tätigkeit: ca. 1,5 Jahre

Fachlicher Hintergrund: Studium der Psychologie mit Schwerpunkt in Bio- und Klinischer Psychologie; Promotion im Bereich Neuro-Ästhetik (kurz vor Fertigstellung)

10 Kernaussagen der Expertin/des Experten:

1. Durch das große Potenzial von Künstlicher Intelligenz und Maschinellem Lernen ist der aktuelle »Hype« zum Teil gerechtfertigt.
2. Feinfühligle Technik geht auf individuelle Bedürfnisse von Nutzer*innen ein, indem sie Gefühlszustände erkennt und auf diese Zustände entsprechend reagiert.
3. Für ein optimales Technikdesign sind vor allem Evaluation, Valenz und Usability wichtig, um den Umgang mit neuen Technologien und Produkten, deren Effizienz und die Fehleranfälligkeit zu untersuchen.
4. Der Einsatz von EEG kann exakte Ergebnisse bei kognitiv-ergonomischen Fragestellungen liefern. Jedoch sollten weitere Technologien, die womöglich besser geeignet sind als das EEG, für die Untersuchung von Emotionen eingesetzt werden.
5. Ein großes Potenzial bieten Deep-Learning-Techniken – gerade für die EEG-Analyse.
6. Die Detektion mentaler Prozesse ist prinzipiell in jeder Lebenslage einsetzbar und bietet großes Potenzial. Hier muss vor allem die Gesellschaft definieren, inwieweit feinfühligle Technik in den Alltag integriert werden soll.
7. Die Herausforderungen, die feinfühligle Technik mit sich bringt, sind in erster Linie nicht auf technischer Ebene, sondern vor allem auf gesellschaftlicher Ebene zu untersuchen.
8. Großes Potenzial für den Einsatz feinfühligler Technik liefern unter anderem auch der Gesundheitssektor (psychische Gesundheit) sowie der Gamingsektor. Weiterhin bieten Smartphones ein großes Potenzial für den Einsatz einer feinfühliglen Technik, um dies zum Beispiel besser im Alltag zu integrieren.
9. Im Umgang mit feinfühligler Technik ist das selbstbestimmte Handeln der Nutzer*innen zwingend erforderlich.

10. Je effizienter die Technik, desto größer wird auch das Risiko einer Manipulation. Jedoch wäre es fatal zu sagen, der Einsatz feinfühligere Technologien wird grundsätzlich ausgeschlossen, nur weil eine Manipulation prinzipiell möglich wäre.

»Künstliche Intelligenz und Maschinelles Lernen sind derzeit ein sehr gehyptes Thema, sozusagen der heilige Gral der Forschung [...] Es wird jedoch noch ein bis zwei Jahrzehnte dauern, bis die Technik voll ausgeschöpft ist.«

»Ich sehe ein großes Potenzial von Machine-Learning-Anwendungen, insbesondere des Deep Learnings, für die Neurowissenschaften, wenn es darum geht, sinnvolle Interpretationen für diese komplexen Signale wie zum Beispiel dem EEG, zu gewinnen.«

»Feinfühligere Technik nimmt die momentan bestehenden Ansätze, erweitert diese um eine neue Ebene und macht sie damit noch effizienter.«

Feinfühligere Technik kann zukünftig die Gruppendynamik in Teams erfassen

Branche: Entwicklung von Neurotechnologien

Position im Unternehmen: 1) Berater*in und administrative Unterstützung der F&E-Abteilung (Interviewpartner 1); 2) Scientific Director (Interviewpartner 2)

Dauer dieser Tätigkeit: 1) seit 14 Jahren; 2) seit knapp einem Jahr

Fachlicher Hintergrund: 1) Studium der Physik und Promotion in der Medizinphysik;
2) Elektrotechnik (BSc + MSc) und Promotion Neurotechnologie & Machine Learning

10 Kernaussagen der Expertin/des Experten:

1. Künstliche Intelligenz und Maschinelles Lernen stellen ein großes Potenzial dar, zeitgleich darf aber auch die Gefahr (wie z. B. die Generierung von Fake News oder die Manipulation der Nutzer*innen) nicht ignoriert werden.
2. Maschinelles Lernen ist bereits in vielen technischen Anwendungen, wie z. B. Smartphones oder digitale Medien, und in unseren Alltag integriert (oftmals unbemerkt).
3. Feinfühligere Technik ist eine Technologie, die sich an die Nutzer*innen anpasst und sich auf sie einstellen kann.
4. Für ein optimales Technikdesign sollte ihre Funktion intuitiv und klar sein, bzw. die Technologie sollte so gestaltet sein, dass ihre Funktion klar erschließbar ist.
5. Großes Potenzial für den Einsatz feinfühligere Technik bietet der Bildungssektor (indem z. B. Lernmaterialien an das Wissen der einzelnen Nutzer*innen angepasst werden), die Selbstoptimierung sowie die Selbstreflektion.

6. Die Berücksichtigung mentaler Prozesse ist vor allem in kritischen Situationen und Berufen mit großer Verantwortung sehr wichtig, um Fehler zu verhindern und die Nutzer*innen zu schützen.
7. Durch den Einsatz feinfühler Technik kann nicht nur der Zustand einzelner Nutzer*innen erfasst und analysiert werden, sondern auch die Gruppendynamik in einem Team. Eine neue vielversprechende Neurotechnologie ist das Hyperscanning. Hiermit kann die (neuro-) physiologische Aktivität von mehreren Nutzer*innen gleichzeitig erfasst werden.
8. Bevor verschiedene Messmethoden (wie z. B. Brain-Computer-Interfaces) eingesetzt werden, muss man sich zunächst immer fragen, worin der wirkliche Mehrwert besteht.
9. Um feinfühler Technik in den Alltag integrieren zu können, muss sie günstig, robust und nicht-invasiv sein. Außerdem sollten die Nutzer*innen zu jedem Zeitpunkt die Möglichkeit haben, über den Umfang des Einsatzes selbst zu bestimmen.
10. Der Einsatz feinfühler Technik sowie deren ethische Fragen müssen gesellschaftlich diskutiert werden.

»Ethisches Dilemma: Auf der einen Seite den Mitarbeiter oder die Mitarbeiterin besser schützen und auf der anderen Seite einen gläsernen Mitarbeiter oder gläserne Mitarbeiterin zu haben. Das ist sehr brisant!«

Mit feinfühler Technik mehr über die Erlebniswelt der Nutzer*innen erfahren

Branche: Maschinenbau

Position im Unternehmen: IT-Leitung

Dauer dieser Tätigkeit: seit 11,5 Jahren

Fachlicher Hintergrund: Maschinenbau und theoretische Informatik; Erfahrungen im Bereich Fast Moving Consumer Goods und Technologieunternehmen

10 Kernaussagen der Expertin/des Experten:

1. In den letzten Jahren wurden die Digitalisierung und die Anwendung von künstlicher Intelligenz immer konkreter, was dieses Themengebiet deutlich spannender gemacht hat.
2. Bei vielen KI-Ideen steht die Vision, aber es ist ein langer Weg von der Vision zur Umsetzung.
3. Bisher werden Eye-tracking-Technologien und Virtual-Reality-Labore eingesetzt, um die Reaktionen und das Verhalten von Konsument*innen in verschiedenen Umgebungen und im Umgang mit verschiedenen Produkten zu untersuchen.
4. Der Einsatz von Neurotechnologien bietet hier einen echten Mehrwert, um mehr über die Erlebniswelt der Kund*innen zu erfahren.

5. Feinfühlige Technik bedeutet: Weg von der klassischen Tastatur-Maus-Interaktion und hin zu einer Interaktion mit dem System über unsere Sinne.
6. Der Einsatz von feinfühligere Technik kann eine große Rolle in der Fabrik der Zukunft spielen – hier muss die Rolle der Mitarbeiter*innen in der »Smart Factory« neu gedacht werden. Dies kann vor allem in der UI-Interaktion mit der Maschine zum Einsatz kommen.
7. Es ist extrem wichtig und sinnvoll, im Bildungssektor auf die Emotionen der Menschen einzugehen, um somit die individuellen Vorkenntnisse als auch unterschiedliche Lerngeschwindigkeiten zu berücksichtigen.
8. Feinfühligere Technologien können im Alter und in der Pflege bei Tätigkeiten unterstützen und Arbeitsabläufe optimieren.
9. Wenn Kundenfeedback noch durch zusätzliche Daten wie die Erfassung der Wahrnehmung und Emotionen bereichert werden könnte, hätte man die Möglichkeit, noch viel genauer auf ein detailliertes Problem hinzuarbeiten.
10. Durch den Einsatz feinfühligere Technologien wird man sich mit einer neuen Dimension von Datenschutz auseinandersetzen müssen.

»Bei Anwendungen in der Smart Factory ist die Individualisierung essenziell, gerade beim Umgang mit dem Lernenden System, bspw. die Führung der Werker*innen bei komplexen Produktionsschritten mit hoher Variantenvielfalt und geringer Losgröße.«

»Gerade in einer Welt mit zunehmender Komplexität wird zielgerichtetes, individuelles Lernen besonders wichtig sein. Hier bietet die Kombination einer AR-Technologie mit einer feinfühligere Technik großes Potenzial, um Lerninhalte besser aufzubereiten und sie somit auf die individuellen Bedürfnisse zuzuschneiden.«

Die Erfassung des Fahrerzustands ermöglicht ein sichereres Autofahren

Branche: Automobil

Position im Unternehmen: UX-Designer in der Abteilung »Serienentwicklung und User Experience«

Dauer dieser Tätigkeit: knapp fünf Jahre

Fachlicher Hintergrund: Medieninformatik (Masterstudium und Promotion), Elektrotechnik (Bachelorstudium) und Ausbildung im Bereich Grafikdesign

10 Kernaussagen der Expertin/des Experten:

1. Künstliche Intelligenz und Maschinelles Lernen können die Arbeit in bestimmten Anwendungsgebieten erleichtern und tun dies auch jetzt schon.

2. Es ist wichtig, bei der Entwicklung und beim Einsatz feinfühler Technik die Ziele der Nutzer*innen zu integrieren bzw. zu beachten und die Effizienz bzw. den Spaß in den Vordergrund zu stellen.
3. Feinfühler Technik erweckt die Assoziation einer Technologie, die auf die Nutzer*innen und deren Bedürfnisse eingeht.
4. In der Automobilbranche wird auch heute schon feinfühler Technik in Form von Emotionserkennung und Eye-tracking eingesetzt.
5. Das größte Potenzial liegt in der Messung bzw. der Kenntnis der mentalen Belastung (Workload). Wenn es da eine robuste und funktionsfähige Technologie gibt, ist dies ein wirklicher Mehrwert für das Autofahren.
6. Je einfacher ein Sensor einzusetzen ist (z. B. fest im Fahrzeug verbaut), umso niedriger ist die Hemmschwelle, diese Technologie auch zu verwenden.
7. Eine robuste Funktion von feinfühler Technik in naher Zukunft eröffnet weitere Anwendungsgebiete, um vor allem die mentale Belastung und das Stresslevel einzelner Nutzer*innen zu erfassen und somit z. B. Müdigkeit frühzeitig zu erkennen und Fehler zu vermeiden.
8. Weitere vielversprechende Anwendungen einer feinfühler Technik liegen im Bereich des Lernmanagements und der Nutzung zur Steigerung der Selbstreflektion, um zum Beispiel das eigene Wohlbefinden im Auge zu behalten.
9. Trotz aller Vorteile spielen Aspekte bei der Datenauswertung, wie die Speicherung von Nutzerdaten und der Datenschutz, eine wichtige Rolle, die kritisch betrachtet werden sollten. Dieser Punkt stellt ein gesellschaftlich relevantes Problem dar.
10. Eine Manipulation durch feinfühler Technik ist möglich. Hierbei muss man jedoch klar zwischen positiver und negativer Manipulation unterscheiden.

»Die Art des Sensors ist relevant, da eine niedrigere Hemmschwelle gegeben ist, wenn etwas schon fest im Fahrzeug verbaut ist.«

»Das interaktive Eintrainieren des Roboterhaltens über die Kenntnisse und den Input der menschlichen Präferenzen halte ich für sehr spannend. Dies wäre ein großer Fortschritt für die Mensch-Roboter-Kollaboration.«

Feinfühlige Technik für »Driver-in-the-Loop«-Anwendungen

Branche: Technologie- und Automobilbranche – Konzernforschung

Position im Unternehmen: Gruppenleitung der Forschungsgruppe
»Human Computer Interaction«

Dauer dieser Tätigkeit: in dieser Position seit drei Jahren (insgesamt 15 Jahre)

Fachlicher Hintergrund: Diplom-Elektrotechnik und technische Kybernetik; Promotion in Maschinenbau mit dem Schwerpunkt Mensch-Maschine-Interaktion

10 Kernaussagen der Expertin/des Experten:

1. Die Begriffe Künstliche Intelligenz und Maschinelles Lernen werden oftmals als Synonyme verwendet, beide beinhalten mächtige Algorithmen, die bei der Problemlösung helfen und unterstützen sollen.
2. Feinfühlige Technik umfasst allgemein gesagt Technologien, die die Emotionen von Nutzer*innen erfassen und darauf eingehen können.
3. Mit dem Einsatz feinfühligere Technik könnte man z. B. im Bereich der User Experience interessante Einblicke in die Nutzung bestimmter Produkte oder Technologien erhalten bzw. diese noch weiter verbessern und anpassen. Dieses Thema gewinnt zunehmend an Bedeutung.
4. Die kontinuierliche Messung mentaler Prozesse während der Nutzung verschiedener Technologien stellt einen großen Mehrwert dar, vor allem in der frühen Phase der Entwicklung.
5. Um feinfühligere Technologien routiniert einsetzen zu können, ist es wichtig, dass die verwendete Sensorik einfach anzubringen ist. Weiterhin bedarf es bei der Interpretation der erhobenen Daten gewisser Routinen, damit man hier nicht auf Expertenwissen angewiesen sein muss.
6. Eine echtzeitfähige Zustandserkennung macht vor allem Sinn beim teilautonomen Fahren, um die mentalen Zustände der Fahrer*innen zu berücksichtigen. Dabei geht es vor allem darum sicherzustellen, dass die Fahrer*innen in der Loop bleiben – »Driver-in-the-Loop«.
7. Brain-Computer-Interfaces sind noch nicht »alltagstauglich« genug, um sie flächendeckend einsetzen zu können.
8. Bisher werden hauptsächlich Eye-tracking-Technologien standardmäßig genutzt, um Nutzerzustände zu detektieren.
9. Die dauerhafte Erfassung mentaler Zustände kann aufgrund des Eingriffs in die Emotionen der Nutzer*innen als Hürde angesehen werden.
10. Aus ethischer Sicht müssen gute Gründe für den echtzeitfähigen Einsatz feinfühligere Technologien gegeben sein, denn es gibt Emotionen, die man nicht teilen möchte. Daher ist es wichtig, transparent gegenüber den Nutzer*innen zu sein und sie in die Entscheidung, welche Zustände gemessen werden sollen, mit einzubeziehen.

»Durch eine kontinuierliche Messung mittels einer feinfühligsten Technik kann man »Motions-that-matter« herausfinden, weil sich nicht ersichtliche Sachen wie Stimmungsveränderung oder Veränderungen in der Herzratenaktivität erkennen lassen.«

Assistenzsysteme mit integrierter feinfühligster Technik helfen und unterstützen

Branche: Technologieunternehmen

Position im Unternehmen: Senior Director Business Development »Innovative Technologien«

Dauer dieser Tätigkeit: in dieser Position seit ca. 1,5 Jahren (elf Jahre insgesamt)

Fachlicher Hintergrund: Studium der Elektrotechnik, Vertriebsmanagement im Bereich Halbleiterkomponenten

10 Kernaussagen der Expertin/des Experten:

1. Künstliche Intelligenz beinhaltet ein großes Potenzial, jedoch sind wir noch weit von »intelligenten« Systemen entfernt.
2. In vielen Fällen wissen Kund*innen oder Mitarbeiter*innen noch zu wenig über künstliche Intelligenz, um diese effektiv in Projekte integrieren zu können.
3. Feinfühligste Technik agiert nicht nur mit Nullen und Einsen, sondern fragt Gefühle ab, bzw. legt diese an den Tag.
4. Der Umgang mit Brain-Computer-Interfaces ist beeindruckend, jedoch muss nun geklärt werden, wie sie am besten ins tägliche Leben bzw. in praxisnahe industrielle Anwendungen integriert werden können.
5. Für ein optimales Technikdesign ist es extrem wichtig, dass die feinfühligste Technik von den Nutzer*innen akzeptiert wird und kaum spürbar ist.
6. Die Erfassung mentaler Zustände ist vor allem in Situationen, in denen die Nutzer*innen in eine stressige oder angespannte Situation geraten, von großem Nutzen.
7. Das größte Anwendungspotenzial feinfühligster Technik liegt in Assistenzsystemen, die den Nutzer*innen bei verschiedenen Tätigkeiten helfen und sie unterstützen (z.B. bei Entscheidungsprozessen). Hier ist es auch sinnvoll, Informationen situationsspezifisch in Datenbrillen (Augmented Reality) zu Verfügung zu stellen – »Connected User«.
8. Mit dem Einsatz von Brain-Computer-Interfaces werden keine Gedanken gelesen, sondern die Reaktionen auf einen gegebenen Reiz gemessen und analysiert.
9. Der Einsatz feinfühligster Technik wie Brain-Computer-Interfaces ist auch eine Datenschutzfrage, was zu deutlichen Nutzungsunterschieden zwischen verschiedenen Ländern führt (Asien vs. Deutschland).

10. Der Einsatz feinfühligere Technik ist am sinnvollsten, wenn Mensch und Maschine sich gegenseitig etwas beibringen. Die Menschen müssen hierbei jedoch die »Schaltzentrale« bleiben. Die Technik soll als unterstützendes Tool für Aufgaben verwendet werden, in denen man sich nicht auskennt bzw. die bestimmte Gefahren bergen.

»Als ich das erste Mal ein BCI-System getestet habe, war ich sehr beeindruckt, wie schnell ein BCI-System auf mich kalibriert werden konnte – innerhalb kürzester Zeit erreichte die Genauigkeit mehr als 80 Prozent.«

»Es wäre bereits ein großer Fortschritt, die Reaktionen des Gehirns auf gestellte Aufgaben zu messen und diese in praktischen Anwendungen zu nutzen.«

Feinfühligere Technik kann die Selbstreflektion steigern

Branche: Technologiepartner

Position im Unternehmen: Senior Consultant – Schnittstelle zwischen Industrie und Forschung

Dauer dieser Tätigkeit: seit fünf Jahren

Fachlicher Hintergrund: Studium der Psychologie; Promotion im Bereich Neurowissenschaften

10 Kernaussagen der Expertin/des Experten:

1. Künstliche Intelligenz und Maschinelles Lernen bietet viele Potenziale, jedoch ist es oft schwierig für Menschen, die sich in diesem Gebiet nicht genügend auskennen, das Thema richtig einzuschätzen und zu beurteilen.
2. Feinfühligere Technik ist in der Lage, sensitiv auf den Nutzerzustand einzugehen und sich ihm anzupassen.
3. Für ein optimales Technikdesign ist es wichtig, die Anwender*innen mit einzubeziehen und in kurzen Abständen die neuesten Entwicklungen mit diesen zu evaluieren und auf Änderungen einzugehen. Erkennungstechnologien werden viel zu Forschungszwecken verwendet.
4. Der Schulungs- und Bildungssektor ist relevant für die Berücksichtigung von mentalen Prozessen. Dies ist aber nur möglich, wenn genügend Material zur Verfügung steht und es nicht zu tiefe/ungewollte Einblicke in den Nutzerzustand liefert.
5. In der Arbeitswelt kann feinfühligere Technik eingesetzt werden, um den optimalen Arbeitsablauf zu bestimmen und das Bewusstsein über den eigenen aktuellen Zustand (Stress, Workload) zu verbessern.
6. Es ist wichtig, feinfühligere Technik langfristig so anzupassen, dass die Interaktion zwischen Nutzer*in und Technologie an den jeweiligen Wissensstand angepasst wird.

7. »Intelligenter« Apps, die auf individuelle Bedürfnisse der Nutzer*innen eingehen, könnten vor allem im Gesundheitswesen von Vorteil sein, um langfristige Entwicklungen z. B. bei chronischen Erkrankungen besser zu analysieren.
8. Hürden beim Einsatz feinfühlicher Technik liegen vor allem in der strengen Regulierung bei der Speicherung von Gesundheitsdaten, die einen direkten Datenaustausch und die Nutzung von gespeicherten Daten einschränkt.
9. Es muss einheitlich beschlossen werden, wie und wo die erfassten Daten gespeichert werden, wer Zugriff darauf hat und für welche Dauer die Daten gespeichert werden sollen.
10. Man muss sich bewusst sein, dass feinfühliche Technik und Personalisierung zu Manipulationen führen kann. Um dies zu vermeiden, müssen Vorrichtungen getroffen werden, was den richtigen Umgang mit feinfühlicher Technik angeht.

»Feinfühlig bedeutet auch, das Gefühl zu haben, nicht fremdgesteuert zu sein – ich als Nutzer*in sollte das Gefühl haben, nicht fremdgesteuert zu werden.«

»Der Einsatz einer echtzeitfähigen feinfühlichen Technik macht gerade im Bereich der Fahrerzustandserkennung Sinn. Hier kann man schauen, ob auch die Aufmerksamkeit wirklich auf der Straße ist.«

3.3.1 Identifizierte Potenziale feinfühligler Technik

Wo sehen Sie am meisten Potenzial für eine Optimierung von Technik auf Basis einer feinfühliglen Technik wie z.B. dem BCI (N = 13)?




Abbildung 19: Antworten der acht Expert*innen auf die Frage: »Wo sehen Sie am meisten Potenzial für eine Optimierung von Technik auf Basis einer feinfühliglen Technik wie z. B. dem BCI?«. Mehrfachantworten möglich.

Die größten Potenziale einer Optimierung von technischen Produkten auf Basis einer feinfühliglen Technik sahen die Expert*innen in industriellen Anwendungen, d. h. in Szenarien, in denen ein Mensch bei monotonen Aufgaben wie zum Beispiel der Überwachung von autonomen Prozessen bei kritischen Infrastrukturen unterstützt werden kann (siehe auch Abbildung 19). Bei solchen Arbeitsaufgaben ist die Erkennung von Stress und mentaler Belastung (Workload) nach Meinung der Expert*innen sinnvoll. Nach Meinung der Expert*innen kann feinfühligle Technik auch für die optimale Gestaltung der »Work-Life-Balance« verwendet werden – unter der Prämisse einer robusten Erkennung mentaler Zustände und einem sicheren und vernünftigen Umgang der erhobenen Daten, beispielsweise um so den Arbeitsablauf zu optimieren und das Bewusstsein über den eigenen aktuellen mentalen Zustand zu verbessern. Dieses Meinungsbild wird komplementiert durch das Rating der aufgezeigten Fallbeispiele, dargestellt in Abbildung 20. Abbildung 21 verdeutlicht noch weitere genannte Einsatzpotenziale der Expert*innen.




Abbildung 20: Anzahl der Antworten, welches Szenario das größte Potenzial für den Einsatz einer feinfühliglen Technik aufweist. Mehrfachantworten möglich.

Wo sehen Sie weitere Potenziale (N = 19)?




Abbildung 21: Antworten der acht Expert*innen auf die Frage: »Wo sehen Sie noch weitere Einsatzpotenziale?«. Mehrfachantworten möglich.

4 FAZIT

In der Studie haben wir Perspektiven, Potenziale und Herausforderungen neuroergonomischer Methoden und Brain-Computer-Interfaces im Sinne einer feinfühligsten Technik aufgezeigt. Dabei wurden gängige Sensortechniken der neuroergonomischen Forschung, welche kognitiven und emotionalen Prozesse sich durch die Sensoren messen lassen, sowie State-of-the-Art-Verfahren der Signalanalyse und des Maschinellen Lernens für die Interpretation der komplexen Signale erläutert. Im zweiten Teil der Studie wurden Praxisbeispiele der neuroergonomischen Forschung und feinfühligsten Technik vorgestellt. Diese zeigen, wie Produkte, Services und Lernprogramme in einem menschenzentrierten Ansatz auf die Präferenzen, Bedürfnisse und Fähigkeiten von Nutzer*innen ausgerichtet werden können. Zudem wurden Zukunftsvisionen zu Interaktionen zwischen Mensch und feinfühligster Technik – ob Maschine, Auto oder Roboter – illustriert. In Interviews mit Anwender*innen sowie Expert*innen wurden der aktuelle Stand, Potenziale, Einsatzbereiche, Forschungsbedarfe im Bereich der feinfühligsten Technik sowie ethische Fragen der Akzeptanz, Datensouveränität und des Datenschutzes diskutiert.

Zusammenfassend zeigen unsere Forschungs- und Entwicklungsarbeiten, die auch die Meinung der Expert*innen reflektieren, dass der größte Mehrwert und das größte Potenzial des Einsatzes einer feinfühligsten Technik in den folgenden Bereichen liegt:

- Nutzerzustandserkennung und die situationssensitive Anpassung der Maschine an die einzelnen Nutzer*innen
- Förderung positiver Emotionen und kognitiver Faktoren (Aufmerksamkeit, Konzentration und Kontrollfähigkeit) in der Interaktion mit feinfühligster Technik
- Interaktives Eintrainieren von Maschinenverhalten mittels BCI-basiertem Reinforcement Learning



Ethische Reflexionen einer feinfühligten Technik

In unserer Forschung spielt Ethik eine wichtige Rolle. Wem gehören die Daten? Wozu werden sie verwendet? Wie vertrauenswürdig sind die Algorithmen? Wie transparent ist das System? Wollen wir eine dauerhafte Optimierung der Menschen im Sinne eines Cyborgs durch eine feinfühligte Technik? Sicher nicht! Unser Ziel ist es, die Menschen in den Mittelpunkt zu stellen und die Technik bzw. die Maschine an die Fähigkeiten und Bedürfnisse der Nutzer*innen anzupassen. Unsere Positionierung ist im Einklang mit dem menschenzentrierten Ansatz. Dabei sollen die Daten nur den einzelnen Nutzen zur Verfügung gestellt werden, sodass sie individuell entscheiden können, wie die Daten weiter verwertet werden, oder wann sie die neuro-adaptive Technologie verwenden möchten und wann nicht.

Weitere Information zur ethischen Gestaltung von Systemen, sowie Reflexionsfragen, die bei der Konzeption des eigenen System unterstützen können, finden sich in der Schwesterstudie »Kundenservice empathisch gestalten« [117]

Gerne stehen Ihnen die Studienautor*innen des Fraunhofer »NeuroLab« als Ansprechpartner*innen mit ihren umfangreichen interdisziplinären Erfahrungen in den Feldern der Positiven Psychologie, Kognitiven Neurowissenschaften, menschengerechten Technik- und Arbeitsgestaltung und des Maschinellen Lernens zur Verfügung. Im Rahmen von Workshops, Schulungen und anwendungsorientierten Forschungsprojekten können Sie die Möglichkeit erhalten, zugeschnittene Neuro-User tests für die Produktevaluation durchzuführen, um empirisch belegte Handlungsempfehlungen und Entscheidungshilfen für den Entwicklungsprozess zu konkretisieren. Weiterhin bieten wir Ihnen die Möglichkeit, im Rahmen von Machbarkeits- und Validierungsstudien erste BCI-basierte Ansätze von adaptiven und autonomen Assistenzsystemen zu pilotieren und zu erproben.

LITERATUR

- [1] M. Vukelić, K. Pollmann, M. Peissner, and D. Spath, "Mensch-Technik-Interaktion mit Emotionen," in Michael Freitag (Hrsg.): Mensch-Technik-Interaktion in der digitalisierten Arbeitswelt, Schriftenreihe der Wissenschaftlichen Gesellschaft für Arbeits- und Betriebsorganisation (WGAB) e.V., 2020, pp. 39–58.
- [2] Matthias Peissner, David Blank, Thomas Norgall, and Martin Wegele, # Zukunftsarbeit - Zukunftsbilder und Handlungsfelder. Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung, 2018.
- [3] D. Spath, M. Peissner, and S. Sproll, "Methods from Neuroscience for Measuring User Experience in Work Environments," in Advances in Understanding Human Performance, vol. 20105280, V. Rice, Ed. CRC Press, 2010, pp. 111–121.
- [4] E. L. Deci and R. M. Ryan, Eds., Handbook of self-determination research, Softcover ed. Rochester, NY: Univ. of Rochester Press, 2004.
- [5] F. Osiurak, J. Navarro, and E. Reynaud, "How Our Cognition Shapes and Is Shaped by Technology: A Common Framework for Understanding Human Tool-Use Interactions in the Past, Present, and Future," Front. Psychol., vol. 9, Mar. 2018, doi: 10.3389/fpsyg.2018.00293.
- [6] S. G. Shamay-Tsoory, J. Aharon-Peretz, and D. Perry, "Two systems for empathy: a double dissociation between emotional and cognitive empathy in inferior frontal gyrus versus ventromedial prefrontal lesions," Brain, vol. 132, no. 3, pp. 617–627, Mar. 2009, doi: 10.1093/brain/awn279.
- [7] A. Stephan, "Empathy for Artificial Agents," Int. J. Soc. Robot., vol. 7, no. 1, pp. 111–116, Feb. 2015, doi: 10.1007/s12369-014-0260-0.

- [8] M. Oehl, K. Ihme, A.-A. Pape, M. Vukelić, and M. Braun, "Affective Use Cases for Empathic Vehicles in Highly Automated Driving: Results of an Expert Workshop," Krömker HCI Mobil. Transp. Automot. Syst. Autom. Driv. -Veh. Exp. Des. Proc. Ptl Second Int. Conf. MobiTAS 2020 Held Part 22nd HCI Int. Conf. HCII 2020 Cph. Den. July 19-24 2020 Held Virtually Cham Springer Nat. 2020 Lect. Notes Comput. Sci. 12212.
- [9] G. A. Miller, "The magical number seven, plus or minus two: some limits on our capacity for processing information.," *Psychol. Rev.*, vol. 63, no. 2, pp. 81–97, 1956, doi: 10.1037/h0043158.
- [10] D. Kahneman, *Objective happiness*, vol. *Well-being: The foundations of hedonic psychology.*, (pp. 3-25). New York, NY, US: Russell Sage Foundation, xii, 593 pp, 1999.
- [11] M. Hassenzahl, "User experience (UX): towards an experiential perspective on product quality," 2008, p. 11, doi: 10.1145/1512714.1512717.
- [12] B. S. Minnery and M. S. Fine, "FEATURENeuroscience and the future of human-computer interaction," *Interactions*, vol. 16, no. 2, pp. 70–75, Mar. 2009, doi: 10.1145/1487632.1487649.
- [13] K. R. Scherer and G. Ceschi, "Criteria for Emotion Recognition from Verbal and Nonverbal Expression: Studying Baggage Loss in the Airport," *Pers. Soc. Psychol. Bull.*, vol. 26, no. 3, pp. 327–339, Mar. 2000, doi: 10.1177/0146167200265006.
- [14] M. Amelang, L. Schmidt-Atzert, T. Fydrich, and W. Zielinski, *Psychologische Diagnostik und Intervention: mit 3 neuen Anwendungsfeldern*, 4., Vollst. überarb. und erw. Aufl. Heidelberg: Springer Medizin, 2006.
- [15] R. E. Nisbett and T. D. Wilson, "Telling more than we can know: Verbal reports on mental processes.," *Psychol. Rev.*, vol. 84, no. 3, pp. 231–259, May 1977, doi: 10.1037/0033-295X.84.3.231.
- [16] L. M. Hirshfield et al., "Brain measurement for usability testing and adaptive interfaces: an example of uncovering syntactic workload with functional near infrared spectroscopy," 2009, p. 2185, doi: 10.1145/1518701.1519035.
- [17] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain Computer Interfaces, a Review," *Sensors*, vol. 12, no. 2, pp. 1211–1279, Jan. 2012, doi: 10.3390/s120201211.

- [18] H. D. Critchley, "Review: Electrodermal Responses: What Happens in the Brain," *The Neuroscientist*, vol. 8, no. 2, pp. 132–142, Apr. 2002, doi: 10.1177/107385840200800209.
- [19] C. Ghaoui, Ed., *Encyclopedia of Human Computer Interaction*: IGI Global, 2006.
- [20] R. el Kaliouby and P. Robinson, "Real-Time Inference of Complex Mental States from Facial Expressions and Head Gestures," in *Real-Time Vision for Human-Computer Interaction*, B. Kisačanin, V. Pavlović, and T. S. Huang, Eds. Boston, MA: Springer US, 2005, pp. 181–200.
- [21] "Measuring facial expression of emotion," *Dialogues Clin. Neurosci.*, vol. 17, no. 4, pp. 457–462, Dec. 2015, doi: 10.31887/DCNS.2015.17.4/kwolf.
- [22] A. Al-Nafjan, M. Hosny, Y. Al-Ohali, and A. Al-Wabil, "Review and Classification of Emotion Recognition Based on EEG Brain-Computer Interface System Research: A Systematic Review," *Appl. Sci.*, vol. 7, no. 12, p. 1239, Dec. 2017, doi: 10.3390/app7121239.
- [23] A. Appriou, A. Cichocki, and F. Lotte, "Modern Machine-Learning Algorithms: For Classifying Cognitive and Affective States From Electroencephalography Signals," *IEEE Syst. Man Cybern. Mag.*, vol. 6, no. 3, pp. 29–38, Jul. 2020, doi: 10.1109/MSMC.2020.2968638.
- [24] L. Shu et al., "A Review of Emotion Recognition Using Physiological Signals," *Sensors*, vol. 18, no. 7, p. 2074, Jun. 2018, doi: 10.3390/s18072074.
- [25] G. K. Verma and U. S. Tiwary, "Multimodal fusion framework: A multiresolution approach for emotion classification and recognition from physiological signals," *NeuroImage*, vol. 102, pp. 162–172, Nov. 2014, doi: 10.1016/j.neuroimage.2013.11.007.
- [26] A.-M. Brouwer, T. O. Zander, J. B. F. van Erp, J. E. Korteling, and A. W. Bronkhorst, "Using neurophysiological signals that reflect cognitive or affective state: six recommendations to avoid common pitfalls," *Front. Neurosci.*, vol. 9, Apr. 2015, doi: 10.3389/fnins.2015.00136.
- [27] S. G. Hart and L. E. Staveland, "Development of NASA-TLX (Task Load Index): Results of Empirical and Theoretical Research," in *Advances in Psychology*, vol. 52, Elsevier, 1988, pp. 139–183.

- [28] M. A. Hogervorst, A.-M. Brouwer, and J. B. F. van Erp, "Combining and comparing EEG, peripheral physiology and eye-related measures for the assessment of mental workload," *Front. Neurosci.*, vol. 8, Oct. 2014, doi: 10.3389/fnins.2014.00322.
- [29] Z. Yin and J. Zhang, "Cross-session classification of mental workload levels using EEG and an adaptive deep learning model," *Biomed. Signal Process. Control*, vol. 33, pp. 30–47, Mar. 2017, doi: 10.1016/j.bspc.2016.11.013.
- [30] A. Myrden and T. Chau, "A Passive EEG-BCI for Single-Trial Detection of Changes in Mental State," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 25, no. 4, pp. 345–356, Apr. 2017, doi: 10.1109/TNSRE.2016.2641956.
- [31] T. Gateau, H. Ayaz, and F. Dehais, "In silico vs. Over the Clouds: On-the-Fly Mental State Estimation of Aircraft Pilots, Using a Functional Near Infrared Spectroscopy Based Passive-BCI," *Front. Hum. Neurosci.*, vol. 12, p. 187, May 2018, doi: 10.3389/fnhum.2018.00187.
- [32] P. Aricò, G. Borghini, G. Di Flumeri, A. Colosimo, S. Pozzi, and F. Babiloni, "A passive brain–computer interface application for the mental workload assessment on professional air traffic controllers during realistic air traffic control tasks," in *Progress in Brain Research*, vol. 228, Elsevier, 2016, pp. 295–328.
- [33] A. Gevins and M. E. Smith, "Neurophysiological measures of cognitive workload during human-computer interaction," *Theor. Issues Ergon. Sci.*, vol. 4, no. 1–2, pp. 113–131, Jan. 2003, doi: 10.1080/14639220210159717.
- [34] P. Aricò, G. Borghini, G. Di Flumeri, N. Sciaraffa, and F. Babiloni, "Passive BCI beyond the lab: current trends and future directions," *Physiol. Meas.*, vol. 39, no. 8, p. 08TR02, Aug. 2018, doi: 10.1088/1361-6579/aad57e.
- [35] J. Scheunemann, A. Unni, K. Ihme, M. Jipp, and J. W. Rieger, "Demonstrating Brain-Level Interactions Between Visuospatial Attentional Demands and Working Memory Load While Driving Using Functional Near-Infrared Spectroscopy," *Front. Hum. Neurosci.*, vol. 12, p. 542, Jan. 2019, doi: 10.3389/fnhum.2018.00542.
- [36] W.-L. Zheng and B.-L. Lu, "A multimodal approach to estimating vigilance using EEG and forehead EOG," *J. Neural Eng.*, vol. 14, no. 2, p. 026017, Apr. 2017, doi: 10.1088/1741-2552/aa5a98.

- [37] A. Gevins et al., "Monitoring Working Memory Load during Computer-Based Tasks with EEG Pattern Recognition Methods," *Hum. Factors J. Hum. Factors Ergon. Soc.*, vol. 40, no. 1, pp. 79–91, Mar. 1998, doi: 10.1518/001872098779480578.
- [38] C. Berka et al., "EEG correlates of task engagement and mental workload in vigilance, learning, and memory tasks," *Aviat. Space Environ. Med.*, vol. 78, no. 5 Suppl, pp. B231-244, May 2007.
- [39] B. Blankertz, C. Schäfer, G. Dornhege, and G. Curio, "Single Trial Detection of EEG Error Potentials: A Tool for Increasing BCI Transmission Rates," in *Artificial Neural Networks — ICANN 2002*, vol. 2415, J. R. Dorronsoro, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2002, pp. 1137–1143.
- [40] R. Chavarriaga, A. Sobolewski, and J. del R. Millán, "Errare machinale est: the use of error-related potentials in brain-machine interfaces," *Front. Neurosci.*, vol. 8, Jul. 2014, doi: 10.3389/fnins.2014.00208.
- [41] L. G. Ricardo Chavarriaga, "Detecting Cognitive States for Enhancing Driving Experience," *Int. BCI Meet. Brain-Comput. Interface 2013 Proc. Fifth Int. Brain-Comput. Interface Meet. Defin. Future June 3-7 2013 Asilomar Conf. Cent. Pac. Grove Calif. USA, Aug. 2015*, doi: 10.3217/978-3-85125-260-6-60.
- [42] H. Zhang, R. Chavarriaga, L. Gheorghe, and J. del R. Millán, "Inferring driver's turning direction through detection of error related brain activity," *Conf. Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. IEEE Eng. Med. Biol. Soc. Annu. Conf.*, vol. 2013, pp. 2196–2199, 2013, doi: 10.1109/EMBC.2013.6609971.
- [43] J.-R. King and S. Dehaene, "Characterizing the dynamics of mental representations: the temporal generalization method," *Trends Cogn. Sci.*, vol. 18, no. 4, pp. 203–210, Apr. 2014, doi: 10.1016/j.tics.2014.01.002.
- [44] A. Vahid, M. Mückschel, A. Neuhaus, A.-K. Stock, and C. Beste, "Machine learning provides novel neurophysiological features that predict performance to inhibit automated responses," *Sci. Rep.*, vol. 8, no. 1, p. 16235, Dec. 2018, doi: 10.1038/s41598-018-34727-7.
- [45] N. Jones, "Computer science: The learning machines," *Nature*, vol. 505, no. 7482, pp. 146–148, Jan. 2014, doi: 10.1038/505146a.

- [46] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, "Deep Learning for Computer Vision: A Brief Review," *Comput. Intell. Neurosci.*, vol. 2018, pp. 1–13, 2018, doi: 10.1155/2018/7068349.
- [47] K. Arai and S. Kapoor, Eds., *Advances in Computer Vision: Proceedings of the 2019 Computer Vision Conference (CVC), Volume 1*, vol. 943. Cham: Springer International Publishing, 2020.
- [48] S. Dargan, M. Kumar, M. R. Ayyagari, and G. Kumar, "A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning," *Arch. Comput. Methods Eng.*, vol. 27, no. 4, pp. 1071–1092, Sep. 2020, doi: 10.1007/s11831-019-09344-w.
- [49] T. Young, D. Hazarika, S. Poria, and E. Cambria, "Recent Trends in Deep Learning Based Natural Language Processing," *ArXiv170802709 Cs*, Nov. 2018, Accessed: Mar. 08, 2021. [Online]. Available: <http://arxiv.org/abs/1708.02709>.
- [50] J. Hirschberg and C. D. Manning, "Advances in natural language processing," *Science*, vol. 349, no. 6245, pp. 261–266, Jul. 2015, doi: 10.1126/science.aaa8685.
- [51] F. Lotte et al., "A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update," *J. Neural Eng.*, vol. 15, no. 3, p. 031005, Jun. 2018, doi: 10.1088/1741-2552/aab2f2.
- [52] B. Blankertz et al., "The Berlin Brain-Computer Interface: Progress Beyond Communication and Control," *Front. Neurosci.*, vol. 10, Nov. 2016, doi: 10.3389/fnins.2016.00530.
- [53] N. Naseer and K.-S. Hong, "fNIRS-based brain-computer interfaces: a review," *Front. Hum. Neurosci.*, vol. 9, Jan. 2015, doi: 10.3389/fnhum.2015.00003.
- [54] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T. H. Falk, and J. Faubert, "Deep learning-based electroencephalography analysis: a systematic review," *J. Neural Eng.*, vol. 16, no. 5, p. 051001, Aug. 2019, doi: 10.1088/1741-2552/ab260c.
- [55] A. Craik, Y. He, and J. L. Contreras-Vidal, "Deep learning for electroencephalogram (EEG) classification tasks: a review," *J. Neural Eng.*, vol. 16, no. 3, p. 031001, Jun. 2019, doi: 10.1088/1741-2552/ab0ab5.

- [56] A. H. Ribeiro et al., "Automatic diagnosis of the 12-lead ECG using a deep neural network," *Nat. Commun.*, vol. 11, no. 1, p. 1760, Dec. 2020, doi: 10.1038/s41467-020-15432-4.
- [57] B. Hwang, J. You, T. Vaessen, I. Myin-Germeys, C. Park, and B.-T. Zhang, "Deep ECGNet: An Optimal Deep Learning Framework for Monitoring Mental Stress Using Ultra Short-Term ECG Signals," *Telemed. E-Health*, vol. 24, no. 10, pp. 753–772, Oct. 2018, doi: 10.1089/tmj.2017.0250.
- [58] N. V. Thakor, "Translating the Brain-Machine Interface," *Sci. Transl. Med.*, vol. 5, no. 210, pp. 210ps17–210ps17, Nov. 2013, doi: 10.1126/scitranslmed.3007303.
- [59] J. J. Vidal, "Toward Direct Brain-Computer Communication," *Annu. Rev. Biophys. Bioeng.*, vol. 2, no. 1, pp. 157–180, Jun. 1973, doi: 10.1146/annurev.bb.02.060173.001105.
- [60] N. Birbaumer et al., "A spelling device for the paralysed," *Nature*, vol. 398, no. 6725, pp. 297–298, Mar. 1999, doi: 10.1038/18581.
- [61] A. Ramos-Murguialday et al., "Brain-machine interface in chronic stroke rehabilitation: A controlled study: BMI in Chronic Stroke," *Ann. Neurol.*, vol. 74, no. 1, pp. 100–108, Jul. 2013, doi: 10.1002/ana.23879.
- [62] A. Kübler et al., "Patients with ALS can use sensorimotor rhythms to operate a brain-computer interface," *Neurology*, vol. 64, no. 10, pp. 1775–1777, May 2005, doi: 10.1212/01.WNL.0000158616.43002.6D.
- [63] J. I. MünlBinger et al., "Brain Painting: First Evaluation of a New Brain–Computer Interface Application with ALS-Patients and Healthy Volunteers," *Front. Neurosci.*, vol. 4, 2010, doi: 10.3389/fnins.2010.00182.
- [64] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clin. Neurophysiol. Off. J. Int. Fed. Clin. Neurophysiol.*, vol. 113, no. 6, pp. 767–791, Jun. 2002.
- [65] J. R. Wolpaw, "Brain-computer interfaces as new brain output pathways," *J. Physiol.*, vol. 579, no. Pt 3, pp. 613–619, Mar. 2007, doi: 10.1113/jphysiol.2006.125948.

- [66] T. Carlson and J. del R. Millan, "Brain-Controlled Wheelchairs: A Robotic Architecture," *IEEE Robot. Autom. Mag.*, vol. 20, no. 1, pp. 65–73, Mar. 2013, doi: 10.1109/MRA.2012.2229936.
- [67] M. Vukelić and A. Gharabaghi, "Oscillatory entrainment of the motor cortical network during motor imagery is modulated by the feedback modality," *NeuroImage*, vol. 111, pp. 1–11, Feb. 2015, doi: 10.1016/j.neuroimage.2015.01.058.
- [68] M. Vukelić, P. Belardinelli, R. Guggenberger, V. Royter, and A. Gharabaghi, "Different oscillatory entrainment of cortical networks during motor imagery and neurofeedback in right and left handers," *NeuroImage*, vol. 195, pp. 190–202, Jul. 2019, doi: 10.1016/j.neuroimage.2019.03.067.
- [69] D. Brauchle, M. Vukelić, R. Bauer, and A. Gharabaghi, "Brain state-dependent robotic reaching movement with a multi-joint arm exoskeleton: combining brain-machine interfacing and robotic rehabilitation," *Front. Hum. Neurosci.*, vol. 9, Oct. 2015, doi: 10.3389/fnhum.2015.00564.
- [70] M. Rohm et al., "Hybrid brain–computer interfaces and hybrid neuroprostheses for restoration of upper limb functions in individuals with high-level spinal cord injury," *Artif. Intell. Med.*, vol. 59, no. 2, pp. 133–142, Oct. 2013, doi: 10.1016/j.artmed.2013.07.004.
- [71] R. Leeb, L. Tonin, M. Rohm, L. Desideri, T. Carlson, and J. del R. Millan, "Towards Independence: A BCI Telepresence Robot for People With Severe Motor Disabilities," *Proc. IEEE*, vol. 103, no. 6, pp. 969–982, Jun. 2015, doi: 10.1109/JPROC.2015.2419736.
- [72] M. Bensch et al., "Nessi: An EEG-Controlled Web Browser for Severely Paralyzed Patients," *Comput. Intell. Neurosci.*, vol. 2007, pp. 1–5, 2007, doi: 10.1155/2007/71863.
- [73] S. Wyckoff and N. Birbaumer, "Neurofeedback and Brain-Computer Interfaces," in *The Handbook of Behavioral Medicine*, D. I. Mostofsky, Ed. Oxford, UK: John Wiley & Sons, Ltd, 2014, pp. 275–312.
- [74] N. Birbaumer, S. Ruiz, and R. Sitaram, "Learned regulation of brain metabolism," *Trends Cogn. Sci.*, vol. 17, no. 6, pp. 295–302, Jun. 2013, doi: 10.1016/j.tics.2013.04.009.
- [75] S. Ruiz et al., "Acquired self-control of insula cortex modulates emotion recognition and brain network connectivity in schizophrenia," *Hum. Brain Mapp.*, vol. 34, no. 1, pp. 200–212, Jan. 2013, doi: 10.1002/hbm.21427.

- [76] S. W. Choi, S. E. Chi, S. Y. Chung, J. W. Kim, C. Y. Ahn, and H. T. Kim, "Is alpha wave neurofeedback effective with randomized clinical trials in depression? A pilot study," *Neuropsychobiology*, vol. 63, no. 1, pp. 43–51, 2011, doi: 10.1159/000322290.
- [77] A.-C. Ehlis, S. Schneider, T. Dresler, and A. J. Fallgatter, "Application of functional near-infrared spectroscopy in psychiatry," *NeuroImage*, vol. 85, pp. 478–488, Jan. 2014, doi: 10.1016/j.neuroimage.2013.03.067.
- [78] C. Seifert et al., "Ubiquitous Access to Digital Cultural Heritage," *J. Comput. Cult. Herit.*, vol. 10, no. 1, pp. 1–27, Apr. 2017, doi: 10.1145/3012284.
- [79] C. Cinel, D. Valeriani, and R. Poli, "Neurotechnologies for Human Cognitive Augmentation: Current State of the Art and Future Prospects," *Front. Hum. Neurosci.*, vol. 13, Jan. 2019, doi: 10.3389/fnhum.2019.00013.
- [80] V. Radu, N. D. Lane, S. Bhattacharya, C. Mascolo, M. K. Marina, and F. Kawsar, "Towards multimodal deep learning for activity recognition on mobile devices," in *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing Adjunct - UbiComp '16*, Heidelberg, Germany, 2016, pp. 185–188, doi: 10.1145/2968219.2971461.
- [81] K. Sankaran, M. Zhu, X. F. Guo, A. L. Ananda, M. C. Chan, and L.-S. Peh, "Using mobile phone barometer for low-power transportation context detection," in *Proceedings of the 12th ACM Conference on Embedded Network Sensor Systems - SenSys '14*, Memphis, Tennessee, 2014, pp. 191–205, doi: 10.1145/2668332.2668343.
- [82] H. Liu, J. Wang, X. Wang, and Y. Qian, "iSee: obstacle detection and feedback system for the blind," in *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers - UbiComp '15*, Osaka, Japan, 2015, pp. 197–200, doi: 10.1145/2800835.2800917.
- [83] K. Mens, R. Capilla, N. Cardozo, and B. Dumas, "A taxonomy of context-aware software variability approaches," in *Companion Proceedings of the 15th International Conference on Modularity - MODULARITY Companion 2016*, Málaga, Spain, 2016, pp. 119–124, doi: 10.1145/2892664.2892684.

- [84] N. Kaklanis et al., "Towards standardisation of user models for simulation and adaptation purposes," *Univers. Access Inf. Soc.*, vol. 15, no. 1, pp. 21–48, Mar. 2016, doi: 10.1007/s10209-014-0371-2.
- [85] W. Bauer and M. Vukelić, "Forschungsprojekt EMOIO," in *Digitalisierung*, R. Neugebauer, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018, pp. 135–151.
- [86] L. Yan, Q. Ma, and M. Yoshikawa, "Classifying Twitter Users Based on User Profile and Followers Distribution," in *Database and Expert Systems Applications*, vol. 8055, H. Decker, L. Lhotská, S. Link, J. Basl, and A. M. Tjoa, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, pp. 396–403.
- [87] R. Gao, B. Hao, S. Bai, L. Li, A. Li, and T. Zhu, "Improving user profile with personality traits predicted from social media content," in *Proceedings of the 7th ACM conference on Recommender systems - RecSys '13*, Hong Kong, China, 2013, pp. 355–358, doi: 10.1145/2507157.2507219.
- [88] C. Besel, J. Schlötterer, and M. Granitzer, "On the quality of semantic interest profiles for online social network consumers," *ACM SIGAPP Appl. Comput. Rev.*, vol. 16, no. 3, pp. 5–14, Nov. 2016, doi: 10.1145/3015297.3015298.
- [89] J. C. R. Licklider, "Man-Computer Symbiosis," *IRE Trans. Hum. Factors Electron.*, vol. HFE-1, no. 1, pp. 4–11, Mar. 1960, doi: 10.1109/THFE2.1960.4503259.
- [90] A. T. Pope, E. H. Bogart, and D. S. Bartolome, "Biocybernetic system evaluates indices of operator engagement in automated task," *Biol. Psychol.*, vol. 40, no. 1–2, pp. 187–195, May 1995.
- [91] T. O. Zander and C. Kothe, "Towards passive brain-computer interfaces: applying brain-computer interface technology to human-machine systems in general," *J. Neural Eng.*, vol. 8, no. 2, p. 025005, Apr. 2011, doi: 10.1088/1741-2560/8/2/025005.
- [92] M. Vukelić, K. Pollmann, and M. Peissner, "Toward Brain-Based Interaction Between Humans and Technology," in *Neuroergonomics*, Elsevier, 2019, pp. 105–109.
- [93] K. Pollmann, D. Ziegler, M. Peissner, and M. Vukelić, "A new Experimental Paradigm for Affective Research in Neuro-adaptive Technologies," vol. *BCIforReal'17*, March 13 2017, Limassol, Cyprus, 2017, doi: <http://dx.doi.org/10.1145/3038439.3038442>.

- [94] M. Vukelić, K. Lingelbach, K. Pollmann, and M. Peissner, "Oscillatory EEG Signatures of Affective Processes during Interaction with Adaptive Computer Systems," *Brain Sci.*, vol. 11, no. 1, p. 35, Dec. 2020, doi: 10.3390/brainsci11010035.
- [95] D. J. McFarland, W. A. Sarnacki, and J. R. Wolpaw, "Brain–computer interface (BCI) operation: optimizing information transfer rates," *Biol. Psychol.*, vol. 63, no. 3, pp. 237–251, Jul. 2003, doi: 10.1016/S0301-0511(03)00073-5.
- [96] S. H. Fairclough, "Fundamentals of physiological computing," *Interact. Comput.*, vol. 21, no. 1–2, pp. 133–145, Jan. 2009, doi: 10.1016/j.intcom.2008.10.011.
- [97] L. J. Hettinger, P. Branco, L. M. Encarnacao, and P. Bonato, "Neuroadaptive technologies: Applying neuroergonomics to the design of advanced interfaces," *Theor. Issues Ergon. Sci.*, vol. 4, no. 1–2, pp. 220–237, Jan. 2003, doi: 10.1080/1463922021000020918.
- [98] L. R. Krol, P. Haselager, and T. O. Zander, "Cognitive and affective probing: a tutorial and review of active learning for neuroadaptive technology," *J. Neural Eng.*, vol. 17, no. 1, p. 012001, Jan. 2020, doi: 10.1088/1741-2552/ab5bb5.
- [99] K. Pollmann, M. Vukelic, and M. Peissner, "Towards affect detection during human-technology interaction: An empirical study using a combined EEG and fNIRS approach," Sep. 2015, pp. 726–732, doi: 10.1109/ACII.2015.7344649.
- [100] T. O. Zander, L. R. Krol, N. P. Birbaumer, and K. Gramann, "Neuroadaptive technology enables implicit cursor control based on medial prefrontal cortex activity," *Proc. Natl. Acad. Sci.*, p. 201605155, Dec. 2016, doi: 10.1073/pnas.1605155114.
- [101] C. Dijksterhuis, D. de Waard, K. A. Brookhuis, B. L. J. M. Mulder, and R. de Jong, "Classifying visuomotor workload in a driving simulator using subject specific spatial brain patterns," *Front. Neurosci.*, vol. 7, 2013, doi: 10.3389/fnins.2013.00149.
- [102] S. Haufe et al., "Electrophysiology-based detection of emergency braking intention in real-world driving," *J. Neural Eng.*, vol. 11, no. 5, p. 056011, Oct. 2014, doi: 10.1088/1741-2560/11/5/056011.

- [103] M. Lahmer, C. Glatz, V. C. Seibold, and L. L. Chuang, "Looming Auditory Collision Warnings for Semi-Automated Driving: An ERP Study," in Proceedings of the 10th International Conference on Automotive User Interfaces and Interactive Vehicular Applications - AutomotiveUI '18, Toronto, ON, Canada, 2018, pp. 310–319, doi: 10.1145/3239060.3239086.
- [104] K. Ihme, A. Unni, M. Zhang, J. W. Rieger, and M. Jipp, "Recognizing Frustration of Drivers From Face Video Recordings and Brain Activation Measurements With Functional Near-Infrared Spectroscopy," *Front. Hum. Neurosci.*, vol. 12, p. 327, Aug. 2018, doi: 10.3389/fnhum.2018.00327.
- [105] F. Dehais, R. N. Roy, and S. Scannella, "Inattentive deafness to auditory alarms: Inter-individual differences, electrophysiological signature and single trial classification," *Behav. Brain Res.*, vol. 360, pp. 51–59, Mar. 2019, doi: 10.1016/j.bbr.2018.11.045.
- [106] F. Dehais et al., "Monitoring Pilot's Mental Workload Using ERPs and Spectral Power with a Six-Dry-Electrode EEG System in Real Flight Conditions," *Sensors*, vol. 19, no. 6, p. 1324, Mar. 2019, doi: 10.3390/s19061324.
- [107] H. Ayaz, P. A. Shewokis, S. Bunce, K. Izzetoglu, B. Willems, and B. Onaral, "Optical brain monitoring for operator training and mental workload assessment," *NeuroImage*, vol. 59, no. 1, pp. 36–47, Jan. 2012, doi: 10.1016/j.neuroimage.2011.06.023.
- [108] C. Walter, W. Rosenstiel, M. Bogdan, P. Gerjets, and M. Spüler, "Online EEG-Based Workload Adaptation of an Arithmetic Learning Environment," *Front. Hum. Neurosci.*, vol. 11, p. 286, May 2017, doi: 10.3389/fnhum.2017.00286.
- [109] C. Mühl, B. Allison, A. Nijholt, and G. Chanel, "A survey of affective brain computer interfaces: principles, state-of-the-art, and challenges," *Brain-Comput. Interfaces*, vol. 1, no. 2, pp. 66–84, Apr. 2014, doi: 10.1080/2326263X.2014.912881.
- [110] G. Liberati, S. Federici, and E. Pasqualotto, "Extracting neurophysiological signals reflecting users' emotional and affective responses to BCI use: A systematic literature review," *NeuroRehabilitation*, vol. 37, no. 3, pp. 341–358, Oct. 2015, doi: 10.3233/NRE-151266.
- [111] I. Krumpal, "Determinants of social desirability bias in sensitive surveys: a literature review," *Qual. Quant.*, vol. 47, no. 4, pp. 2025–2047, Jun. 2013, doi: 10.1007/s11135-011-9640-9.

- [112] K. Pollmann, O. Stefani, A. Bengsch, M. Peissner, and M. Vukelić, "How to Work in the Car of the Future?: A Neuroergonomical Study Assessing Concentration, Performance and Workload Based on Subjective, Behavioral and Neurophysiological Insights," in Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems - CHI '19, Glasgow, Scotland Uk, 2019, pp. 1–14, doi: 10.1145/3290605.3300284.
- [113] R. W. Picard, E. Vyzas, and J. Healey, "Toward machine emotional intelligence: analysis of affective physiological state," IEEE Trans. Pattern Anal. Mach. Intell., vol. 23, no. 10, pp. 1175–1191, Oct. 2001, doi: 10.1109/34.954607.
- [114] S. Stöckli, M. Schulte-Mecklenbeck, S. Borer, and A. C. Samson, "Facial expression analysis with AFFDEX and FACET: A validation study," Behav. Res. Methods, vol. 50, no. 4, pp. 1446–1460, Aug. 2018, doi: 10.3758/s13428-017-0996-1.
- [115] D. McDuff, A. Mahmoud, M. Mavadati, M. Amr, J. Turcot, and R. el Kaliouby, "AFFDEX SDK: A Cross-Platform Real-Time Multi-Face Expression Recognition Toolkit," in Proceedings of the 2016 CHI Conference Extended Abstracts on Human Factors in Computing Systems, San Jose California USA, May 2016, pp. 3723–3726, doi: 10.1145/2851581.2890247.
- [116] R. K. Kosuru, K. Lingelbach, M. Bui, and M. Vukelić, "MindTrain: How to Train Your Mind with Interactive Technologies," in Proceedings of Mensch und Computer 2019 on - MuC'19, Hamburg, Germany, 2019, pp. 643–647, doi: 10.1145/3340764.3344884
- [117] N. Fronemann, D. Janssen, K. Pollmann. "Kundenservice empathisch gestalten. Mit intelligenten Systemen zu einer nutzerzentrierten Kundenkommunikation". In KI-Fortschrittszentrum Lernende Systeme, Wilhelm Bauer, Oliver Riedel, Thomas Renner and Matthias Peissner, Eds., Stuttgart, 2021.



KI-FORTSCHRITTSZENTRUM

Das KI-Fortschrittszentrum »Lernende Systeme« unterstützt Firmen dabei, die wirtschaftlichen Chancen der Künstlichen Intelligenz und insbesondere des Maschinellen Lernens für sich zu nutzen. In anwendungsnahen Forschungsprojekten und in direkter Kooperation mit Industrieunternehmen arbeiten die Stuttgarter Fraunhofer-Institute für Arbeitswirtschaft und Organisation IAO sowie für Produktionstechnik und Automatisierung IPA daran, Technologien aus der KI-Spitzenforschung in die breite Anwendung der produzierenden Industrie und der Dienstleistungswirtschaft zu bringen. Finanzielle Förderung erhält das Zentrum vom Ministerium für Wirtschaft, Arbeit und Wohnungsbau Baden-Württemberg.

Europas größte Forschungsk Kooperation auf dem Gebiet der KI

Das KI-Forschungszentrum ist Forschungspartner des Cyber Valley, einem Konsortium aus den renommierten Universitäten Tübingen und Stuttgart, dem Max-Planck-Institut für intelligente Systeme und einigen führenden Industrieunternehmen. In gemeinsamen Forschungslabors werden Grundlagenforschung und anwendungsorientierte Entwicklung zu aktuellen wie auch zukünftigen Bedarfen behandelt und vorangetrieben.

Menschzentrierte KI

Alle Aktivitäten des Zentrums verfolgen das Ziel, eine menschzentrierte KI zu entwickeln, der die Menschen vertrauen und die sie akzeptieren. Nur wenn Menschen mit neuen Technologien intuitiv interagieren und vertrauensvoll zusammenarbeiten, kann deren Potenzial optimal ausgeschöpft werden. Daher konzentrieren sich die Forschungsaktivitäten unter anderem auf die Themen Erklärbarkeit, Datenschutz, Sicherheit und Robustheit von KI-Technologien.

Studienreihe »Lernende Systeme«

Die Studienreihe »Lernende Systeme« gibt Einblick in die Potenziale und die praktischen Einsatzmöglichkeiten von KI. Nähere Informationen und die aktuellen Versionen der Studien finden Sie unter: www.ki-fortschrittszentrum.de/studien

FRAUNHOFER-GESELLSCHAFT

Forschen für die Praxis ist die zentrale Aufgabe der Fraunhofer-Gesellschaft. Die 1949 gegründete Forschungsorganisation betreibt anwendungsorientierte Forschung zum Nutzen der Wirtschaft und zum Vorteil der Gesellschaft. Vertragspartner und Auftraggeber sind Industrie- und Dienstleistungsunternehmen sowie die öffentliche Hand.

Die Fraunhofer-Gesellschaft betreibt in Deutschland derzeit 74 Institute und Forschungseinrichtungen. Mehr als 28000 Mitarbeiterinnen und Mitarbeiter, überwiegend mit natur- oder ingenieurwissenschaftlicher Ausbildung, erarbeiten das jährliche Forschungsvolumen von mehr als 2,8 Milliarden Euro. Davon entfallen mehr als 2,3 Milliarden Euro auf den Leistungsbereich Vertragsforschung. Rund 70 Prozent dieses Leistungsbereichs erwirtschaftet die Fraunhofer-Gesellschaft mit Aufträgen aus der Industrie und mit öffentlich finanzierten Forschungsprojekten. Rund 30 Prozent werden von Bund und Ländern als Grundfinanzierung beigesteuert, damit die Institute Problemlösungen entwickeln können, die erst in fünf oder zehn Jahren für Wirtschaft und Gesellschaft aktuell werden.

Internationale Kooperationen mit exzellenten Forschungspartnern und innovativen Unternehmen weltweit sorgen für einen direkten Zugang zu den wichtigsten gegenwärtigen und zukünftigen Wissenschafts- und Wirtschaftsräumen.

Mit ihrer klaren Ausrichtung auf die angewandte Forschung und ihrer Fokussierung auf zukunftsrelevante Schlüsseltechnologien spielt die Fraunhofer-Gesellschaft eine zentrale Rolle im Innovationsprozess Deutschlands und Europas. Die Wirkung der angewandten Forschung geht über den direkten Nutzen für die Kund*innen hinaus: Mit ihrer Forschungs- und Entwicklungsarbeit tragen die Fraunhofer-Institute zur Wettbewerbsfähigkeit der Region, Deutschlands und Europas bei. Sie fördern Innovationen, stärken die technologische Leistungsfähigkeit, verbessern die Akzeptanz moderner Technik und sorgen für die Aus- und Weiterbildung des dringend benötigten wissenschaftlich-technischen Nachwuchses.

Ihren Mitarbeiterinnen und Mitarbeitern bietet die Fraunhofer-Gesellschaft die Möglichkeit zur fachlichen und persönlichen Entwicklung für anspruchsvolle Positionen in ihren Instituten, an Hochschulen, in Wirtschaft und Gesellschaft. Studierenden eröffnen sich aufgrund der praxisnahen Ausbildung und Erfahrung an Fraunhofer-Instituten hervorragende Einstiegs- und Entwicklungschancen in Unternehmen.

Namensgeber der als gemeinnützig anerkannten Fraunhofer-Gesellschaft ist der Münchner Gelehrte Joseph von Fraunhofer (1787–1826). Er war als Forscher, Erfinder und Unternehmer gleichermaßen erfolgreich.

Fraunhofer IAO

Mensch und Technik in der digitalen Arbeitswelt, Wirtschaft und Gesellschaft

Digitale Technologien verändern unsere Arbeitswelt und haben tiefgreifende Auswirkungen auf Wirtschaft und Gesellschaft. Lang etablierte Methoden und Prozesse werden in kurzer Zeit modernisiert und revolutioniert. Das Fraunhofer IAO kooperiert eng mit dem Partnerinstitut IAT der Universität Stuttgart und entwickelt gemeinsam mit Unternehmen, Institutionen und Einrichtungen der öffentlichen Hand wirksame Strategien, Geschäftsmodelle und Lösungen für die digitale Transformation.

Die digitale Transformation und neue IT-Technologien eröffnen für Unternehmen viele Chancen: innovative Produktangebote für neue Zielgruppen, bessere und kostengünstigere Prozesse, eine »intelligenter« Kundenkommunikation und höhere Automatisierung. Dafür kommen innovative, vernetzte IT-Lösungen auf Basis von Big Data, Künstlicher Intelligenz, Cloud und Internetplattformen zum Einsatz.

Die richtige Strategie und IT sind eine wesentliche Grundlage für den Erfolg und die Wettbewerbsfähigkeit von Unternehmen. Voraussetzung für erfolgreiche Anwendungen ist ein klarer Nutzen für das Unternehmen, seine Kund*innen und seine Partner.

Unsere Leistungen basieren auf fundierter Technologie- und Marktkenntnis sowie branchenübergreifenden Erfahrungen. Durch den Einsatz unserer praxiserprobten Methoden und erfahrenen Mitarbeitenden sichern wir den Projekterfolg. Unser Fraunhofer-Netzwerk ermöglicht uns den Zugriff auf ein umfassendes Kompetenzspektrum.

Das Fraunhofer IAO und das IAT der Universität Stuttgart beschäftigen gemeinsam mehr als 650 Mitarbeitende und verfügen über rund 15 000 Quadratmeter Büroflächen, Demonstrationen sowie Entwicklungs- und Testlabors.

ANSPRECHPERSONEN

Dr. rer. nat. Mathias Vukelić

Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO, Stuttgart

Mathias Vukelić promovierte 2014 an der International Max Planck Research School der Universität Tübingen mit den Schwerpunkten Neuro- und Verhaltenswissenschaften und Brain-Computer-Interfaces. Zuvor erwarb er einen Masterabschluss in Biomedizinischer Technik mit Schwerpunkt Neural Engineering. Von 2014-2015 arbeitete er als akademischer Mitarbeiter (Postdoc) in der Abteilung für Funktionelle und Restaurative Neurochirurgie am Universitätsklinikum Tübingen. Seine Forschungsschwerpunkte waren Neuromodulation des motorischen Lernens, Brain-Robotic-Interfaces, Neurofeedback und Schlaganfall-Rehabilitation. Am Fraunhofer IAO in Stuttgart arbeitet er seit 2015 und leitet das »NeuroLab« - Angewandte Neurowissenschaften und Neuroadaptive Technologien - im Forschungsbereich Mensch-Technik-Interaktion. Ziel seiner Forschung im »NeuroLab« ist, die menschliche Motivation, Kognition und Emotionen und die ihnen zugrundeliegenden Hirnfunktionen besser zu verstehen und so ein positives Erlebnis im Umgang mit digitalen Techniken sowie die individuellen Stärken und das subjektive Wohlbefinden des Menschen bei der Arbeit zu fördern. Seine Forschungsschwerpunkte sind Neuroergonomie, neuro-adaptive Technologien, Affective Computing, Maschinelles Lernen und neuronale Mechanismen von Kognition und Emotionen.



Katharina Lingelbach, M. Sc.

Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO, Stuttgart

Katharina Lingelbach ist wissenschaftliche Mitarbeiterin und Doktorandin im »NeuroLab« – Angewandte Neurowissenschaften und Neurotechnologien im Forschungsbereich Mensch-Technik-Interaktion am Fraunhofer IAO in Stuttgart. Ihre Promotion absolviert sie an der Universität Oldenburg in der Forschungsgruppe Angewandte Neurokognitive Psychologie. Sie untersucht in ihrem Promotionsprojekt die Interaktion von affektiven und kognitiven Prozessen auf neuronaler Ebene. Dabei ist sie besonders an der Enkodierung und Dekodierung der neuronalen Aktivierungsmuster affektiver und kognitiver Prozesse mittels Machine Learning Methoden interessiert. Ihren Bachelor und Master absolvierte sie an der Universität Wien im Bereich Psychologie mit dem Schwerpunkt Kognitions- und Neurowissenschaften. In verschiedenen Forschungs- und Industrieprojekten im NeuroLab des Fraunhofer IAO arbeitet sie an der



ANSPRECHPERSONEN

Nutzerzustandserkennung aus multimodalen Sensordaten während der Mensch-Technik-Interaktion und ist besonders daran interessiert, wie diese Methoden zur Nutzerzustandserkennung in neuro-adaptiven Closed-Loop-Systemen genutzt werden können.

Kontaktadresse

Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO
Nobelstraße 12, 70569 Stuttgart

Autorinnen und Autoren

Mathias Vukelić
Telefon +49 711 970-5183
mathias.vukelic@iao.fraunhofer.de

Katharina Lingelbach
Telefon +49 711 970-5342
katharina.lingelbach@iao.fraunhofer.de

Herausgeber

Wilhelm Bauer, Oliver Riedel, Thomas Renner, Matthias Peissner

Satz und Gestaltung

Franz Schneider, Fraunhofer IAO

URN-Nummer

[urn:nbn:de:0011-n-6306874](https://nbn-resolving.org/urn:nbn:de:0011-n-6306874)

Online verfügbar als Fraunhofer-ePrint

<http://publica.fraunhofer.de/dokumente/N-630687.html>

Gefördert durch das Ministerium für Wirtschaft, Arbeit und
Wohnungsbau Baden-Württemberg



Gefördert durch



Baden-Württemberg

MINISTERIUM FÜR WIRTSCHAFT, ARBEIT UND WOHNUNGSBAU

CyberValley

