

Warum die ASU den Mut zum unkonventionellen Denken wagt

Liebe Leserinnen und Leser,

die Kernaufgabe der Arbeits-, Sozial- und Umweltmedizin ist es, den Menschen in seiner Gesamtheit und in Wechselwirkung mit seiner Umwelt zu betrachten. Wir untersuchen komplexe Zusammenhänge und stellen uns Fragen wie: Wie wirken chemische Toxine, psychischer Stress, soziale Arbeitsbedingungen und biologische Erreger auf den menschlichen Organismus ein? Doch je komplexer die Herausforderungen unserer Zeit werden, desto dringlicher wird es, uns als wissenschaftliche Gemeinschaft in diesem Zusammenhang auch eine selbstkritische Frage zu stellen: Passt denn das wissenschaftliche Publikationssystem, mit dessen Hilfe wir unsere Studienergebnisse publik machen, in seiner jetzigen Form überhaupt noch, um echte wissenschaftliche Durchbrüche zuzulassen?

In seinem aktuellen Werk „Nexus“ warnt der Historiker Yuval Noah Harari eindringlich vor einer strukturellen Trägheit moderner Informationsnetzwerke (Harari 2024). Er legt dar, dass bürokratische Systeme – zu denen auch das akademische Publikationswesen mit seinen starren Peer-Review-Verfahren gehört – dazu neigen, den Erhalt der bestehenden Ordnung und den Konsens auf der Basis etablierten Wissens über die Suche nach neuen Wahrheiten zu stellen. Das System filtert das Unkonventionelle oft instinktiv heraus, weil es nicht in den gängigen, linearen Bewertungsrahmen passt.

Die Geschichte der Medizin zeigt, wie recht Harari mit dieser Analyse hat, wenn wir uns zum Beispiel an Harald zur Hausen und dessen These erinnern, dass Gebärmutterhalskrebs durch Viren (HPV) ausgelöst wird. Er wurde jahrzehntelang vom medizinischen Establishment belächelt und blockiert – bis er 2008 den Nobelpreis erhielt (Zur Hausen 2002). Ein weiteres Beispiel sind Robin Warren und Barry Marshall, die durch einen Selbstversuch ihre Theorie beweisen mussten, dass das Bakterium *Helicobacter pylori* für die Entstehung von Magengeschwüren verantwortlich ist – eine Theorie, die von der etablierten Fachwelt kategorisch abgelehnt wurde (Marshall u. Warren 1984). Sie erhielten den Nobelpreis im Jahr 2005. Oder wenn wir an Katalin Karikó denken, deren Anträge auf Forschungsförderung für die mRNA-Technologie über Jahre hinweg konsequent abgelehnt wurden, weil man die Idee für zu riskant und unrealistisch hielt (Karikó et al. 2008; Nobelpreis 2023). Ohne ihre Hartnäckigkeit gegen die Widerstände des akademischen Betriebs hätte die COVID-19-Pandemie nicht so schnell eingedämmt werden können. Es ist offensichtlich, dass unser akademisches System selten aus Einsicht lernt, sondern eher in Krisen dazu gezwungen wird.

Eine solche Krise erleben wir aktuell als Folge der COVID-19-Pandemie bei den postinfektiösen und umweltassoziierten Systemerkrankungen wie ME/CFS (Myalgische Enzephalomyelitis/Chronic Fatigue Syndrome) und Long COVID. Jahrzehntlang wurde ME/CFS in eine psychosomatische Nische gedrängt, weil es nicht in

das lineare, reduktionistische Denken der klassischen Medizin passte. Sie sucht für jede Krankheit einen spezifischen Defekt in einem Organ. Und bisher gab es ja auch viele Erfolge bei der Anwendung dieser Art des Denkens. Neuere Arbeiten aus der Systembiologie zeigen jedoch als Basis der Entstehung von chronischen Erkrankungen einen völlig anderen, netzwerkbasierten Mechanismus (z. B. Naviaux 2014 mit Wang et al. 2023).

Warum dringen solche Erkenntnisse so langsam in den klinischen Alltag vor? Es ist für klassische Förderkommissionen und traditionelle Fachzeitschriften nach wie vor einfacher, in linearen Kausalitäten zu denken („Virus X ruft Symptom Y hervor“), als multikausale, systemische Netzwerke zu begreifen. Die ASU möchte dieses Nadelöhr des Wissenskreislaufs bewusst aufbrechen. Wir wollen nicht nur den etablierten Konsens wiedergeben, sondern auch neuen, unkonventionellen, systemischen Ideen eine Plattform bieten. Das heißt, wir wollen in unserem Wissenschaftsteil ab sofort explizit auch Forschungsansätze publizieren, die dem Mainstream widersprechen oder tradierte Dogmen infrage stellen, wenn sie methodisch sauber begründet und mit validen Daten unterlegt sind.

Wir laden daher alle Forscherinnen und Forscher ein, interdisziplinär und unkonventionell zu denken. Die Fälle von zur Hausen, Warren und Marshall, Karikó und die aktuelle Debatte um ME/CFS sollten uns lehren, dass die Medizin der Zukunft in der Regel nicht auf dem alten Konsens beruht, sondern dass es Mut zu neuen Perspektiven braucht.

Dr. med. Lotte Habermann-Horstmeier, MPH, MSc.

Chefredakteurin der ASU

Literatur

Harari YN. *Nexus: Eine kurze Geschichte der Informationsnetzwerke von der Steinzeit bis zur KI*. München: C.H. Beck, 2024.

Karikó K, Muramatsu H, Welsh FA et al. Incorporation of pseudouridine into mRNA yields a superior nonimmunogenic vector with increased translational capacity and biological stability. *Mol Ther* 2008; 16(11): 1833–1840. <https://doi.org/10.1038/mt.2008.200>

Marshall BJ, Warren JR. Unidentified curved bacilli in the stomach of patients with gastritis and peptic ulceration. *Lancet* 1984;1(8390):1311–1315. [https://doi.org/10.1016/s0140-6736\(84\)91816-6](https://doi.org/10.1016/s0140-6736(84)91816-6)

Naviaux RK. Metabolic features of the cell danger response. *Mitochondrion* 2014; 16: 7–17. <https://doi.org/10.1016/j.mito.2013.08.006>

Wang P-Y, Ma J, Kim Y-C et al. WASF3 disrupts mitochondrial respiration and may mediate exercise intolerance in myalgic encephalomyelitis/chronic fatigue syndrome. *Proc Natl Acad Sci U S A* 2023; 120(34): e2302738120. <https://doi.org/10.1073/pnas.2302738120>

Zur Hausen H. Papillomaviruses and cancer: from basic studies to clinical application. *Nat Rev Cancer* 2002; 2(5): 342–350. <https://doi.org/10.1038/nrc798>

Kennzahlen im Betrieblichen Gesundheitsmanagement: Analyse allgemeiner und arbeitsbezogener Gesundheitskompetenz zur Vorhersage der Arbeitsfähigkeit durch Erklärbare Künstliche Intelligenz

Julian Friedrich, Filip Mess, Simon Blaschke

Worum geht es?

Der Beitrag untersucht, wie allgemeine und arbeitsbezogene Gesundheitskompetenz sowie gesundheitsbezogene Lebensqualität mit der Arbeitsfähigkeit zusammenhängen. Zudem wird aufgezeigt, wie diese Faktoren im Betrieblichen Gesundheitsmanagement (BGM) systematisch erfasst und mithilfe Erklärbarer Künstlicher Intelligenz (Explainable Artificial Intelligence, XAI) transparent dargestellt werden können.

Ziel der Studie

Ziel des Beitrags ist es, Gesundheitskompetenz als relevanten Treiber der Arbeitsfähigkeit in einem ganzheitlichen Kennzahlensystem des BGM zu verorten. Darüber hinaus soll gezeigt werden, wie XAI zur Analyse von Risiko- und Schutzfaktoren eingesetzt werden kann, um die Arbeitsfähigkeit vorherzusagen und daraus passgenaue Gesundheitsförderungsmaßnahmen abzuleiten.

Methoden

Grundlage ist eine querschnittliche Online-Befragung unter 1997 erwerbstätigen Personen in Deutschland. Erhoben wurden allgemeine und arbeitsbezogene Gesundheitskompetenz, gesundheitsbezogene Lebensqualität, Arbeitsfähigkeit, Arbeitsunfähigkeitstage sowie soziodemografische Merkmale. Zur Analyse wurden prädiktive Modelle des maschinellen Lernens eingesetzt.

Ergebnisse

Die physische und mentale Lebensqualität erwiesen sich als die stärksten Prädiktoren¹ der Arbeitsfähigkeit. Zusätzlich leisteten allgemeine und arbeitsbezogene Gesundheitskompetenz relevante

Beiträge zur Vorhersage der Arbeitsfähigkeit. XAI ermöglichte die Identifikation individueller Risiko- und Ressourcenprofile. Exemplarische Wenn-dann-Szenarien verdeutlichten, dass insbesondere Verbesserungen der arbeitsbezogenen Gesundheitskompetenz und der Lebensqualität die Wahrscheinlichkeit einer kritischen Arbeitsfähigkeit deutlich senken können.

Möglichkeiten der Umsetzung der Erkenntnisse in die Praxis

Die Ergebnisse sprechen dafür, BGM-Kennzahlensysteme stärker auf präventiv nutzbare Treiber- und Frühindikatoren auszurichten. Folgende Ansatzpunkte ergeben sich für die betriebliche Praxis:

- *Verknüpfung von Treiber-, Früh- und Spätindikatoren* in Kennzahlensystemen, um ein ganzheitliches Verständnis von Gesundheit in die BGM- und Unternehmensstrategie einzubeziehen.
- *Einsatz von XAI-Analysen*, um Risiken und Ressourcen auch bei großen Datenmengen empirisch fundiert zu identifizieren, zu gewichten und nachvollziehbar darzustellen.
- *Ableitung passgenauer Maßnahmen* für Beschäftigtengruppen, Abteilungen und einzelne Beschäftigte auf Grundlage individueller Risiko- und Ressourcenprofile.

Der Beitrag weist darauf hin, dass BGM-Kennzahlensysteme nicht nur rückblickend Fehlzeiten abbilden, sondern vor allem frühzeitig steuerungsrelevante Risiken und Ressourcen sichtbar machen sollten. XAI-Analysen können dabei helfen, diese Informationen nachvollziehbar aufzubereiten und für eine gezielte Maßnahmenplanung nutzbar zu machen.

¹ Prädiktoren = Vorhersagevariablen. In der Regel sind dies im Gesundheitsbereich Risiko- und Schutzfaktoren, mit deren Hilfe wissenschaftlich belegte Vorhersagen zur Wahrscheinlichkeit des Auftretens oder Nicht-Auftretens eines Problems gemacht werden können.

Kennzahlen im Betrieblichen Gesundheitsmanagement: Analyse allgemeiner und arbeitsbezogener Gesundheitskompetenz zur Vorhersage der Arbeitsfähigkeit durch Erklärbare Künstliche Intelligenz

Julian Friedrich
Filip Mess
Simon Blaschke

Technische Universität München, TUM School of Medicine and Health,
Professur für Sport- und Gesundheitsdidaktik

(eingegangen am 19.12.2025, angenommen am 15.06.2026)

ABSTRACT / ZUSAMMENFASSUNG

Key performance indicators in occupational health management: Analysis of general and occupational health literacy for prediction of workability using explainable artificial intelligence

Objectives: The aim of this study is to identify general and occupational health literacy as drivers, alongside selected leading and lagging indicators, to determine workability within a holistic key performance indicator system for Occupational Health Services (OHS). Furthermore, it demonstrates how explainable artificial intelligence (XAI) can be used to provide transparent, personalized analysis of risk and protective factors to predict employee workability and develop tailored health promotion programs.

Methods: The analysis is based on a cross-sectional online survey of $n = 1,997$ working adults in Germany. The following were collected: general health literacy, occupational health literacy, health-related quality of life, workability, sick leave days, and socio-demographic characteristics. Predictive models were used to investigate the relationships. The model predictions were made explainable using XAI analyses to quantify the influence of individual variables at an aggregated and individual level.

Results: The physical and mental components of health-related quality of life were the strongest predictors of workability. Occupational and general health literacy showed additional, relevant moderate contributions to predict workability. XAI analyses enabled the identification of individual risk and resource profiles of the working adults. These showed, using an example person at the sample means, that high occupational health literacy is a protective factor and low physical health-related quality of life is a risk factor for critical workability. If-then scenarios at the individual level illustrated that targeted improvements in occupational health literacy and health-related quality of life substantially reduce the model-based probability of critical workability.

Conclusions: The findings underscore the importance of holistic key performance indicator systems in OHS that systematically integrate both drivers, such as occupational health literacy, and leading indicators, such as workability. Within such systems, XAI offers substantial potential for evidence-based decision support by quantifying risks and making them explainable. In addition, if-then scenarios can support practitioners by prioritizing interventions and enhancing the transparency of strategies in

Kennzahlen im Betrieblichen Gesundheitsmanagement: Analyse allgemeiner und arbeitsbezogener Gesundheitskompetenz zur Vorhersage der Arbeitsfähigkeit durch Erklärbare Künstliche Intelligenz

Zielstellung: Ziel des Beitrags ist es, allgemeine und arbeitsbezogene Gesundheitskompetenz als Treiber mit ausgewählten Früh- und Spätindikatoren zur Bestimmung der Arbeitsfähigkeit innerhalb eines ganzheitlichen Kennzahlensystems im Betrieblichen Gesundheitsmanagement (BGM) zu verorten. Darüber hinaus wird aufgezeigt, wie Erklärbare Künstliche Intelligenz (Explainable Artificial Intelligence, XAI) zur transparenten und personalisierten Analyse von Risiko- und Schutzfaktoren eingesetzt werden kann, um die Arbeitsfähigkeit von Beschäftigten vorherzusagen und daraus adressatenorientierte Gesundheitsförderungsmaßnahmen abzuleiten.

Methode: Die Analyse basiert auf einer querschnittlichen Online-Befragung mit $n = 1997$ erwerbstätigen Personen in Deutschland. Erhoben wurden allgemeine Gesundheitskompetenz, arbeitsbezogene Gesundheitskompetenz, gesundheitsbezogene Lebensqualität, Arbeitsfähigkeit, Arbeitsunfähigkeitstage sowie soziodemografische Merkmale. Zur Untersuchung der Zusammenhänge wurden prädiktive Modelle eingesetzt. Die Modellvorhersagen wurden mithilfe von XAI-Analysen erklärbar gemacht, um den Einfluss einzelner Variablen auf aggregierter und individueller Ebene zu quantifizieren.

Ergebnisse: Physische und mentale Lebensqualität erwiesen sich als die stärksten Prädiktoren der Arbeitsfähigkeit. Arbeitsbezogene und allgemeine Gesundheitskompetenz zeigten zusätzliche, relevante moderate Beiträge zur Vorhersage der Arbeitsfähigkeit. XAI-Analysen ermöglichten die Identifikation individueller Risiko- und Ressourcenprofile der Erwerbstätigen. Diese zeigten bei einer exemplarisch ausgewählten Person am Stichprobenmittel, dass eine hohe arbeitsbezogene Gesundheitskompetenz als Schutzfaktor und eine geringe physische Lebensqualität als Risikofaktor für eine kritische Arbeitsfähigkeit fungieren. Wenn-dann-Szenarien auf individueller Ebene verdeutlichten, dass gezielte Verbesserungen der arbeitsbezogenen Gesundheitskompetenz und der Lebensqualität die modellbasierte Wahrscheinlichkeit kritischer Arbeitsfähigkeit deutlich reduzieren.

Schlussfolgerungen: Die Ergebnisse unterstreichen, dass sowohl Treiber wie die arbeitsbezogene Gesundheitskompetenz als auch Frühindikatoren wie die Arbeitsfähigkeit in BGM-Kennzahlensystemen systematisch berücksich-

OHS. Moreover, XAI analyses can be integrated into personalized digital health assistance systems.

Keywords: precision prevention – occupational health services – key performance indicators – decision support systems – risk assessment

doi:10.17147/asu-1-551456

ASU Arbeitsmed Sozialmed Umweltmed 2026; 61: 495–504

tigt werden sollten und eine hohe Relevanz für die Planung und Steuerung betrieblicher Gesundheitsmaßnahmen aufweisen. XAI bietet in Kennzahlensystemen ein hohes Potenzial für evidenzbasierte Entscheidungsunterstützung, indem Risiken quantifiziert und erklärbar gemacht werden. Wenn-dann-Szenarien können darüber hinaus BGM-Verantwortlichen dabei helfen, Maßnahmen zu priorisieren und BGM-Strategien transparenter darzustellen. Zudem lassen sich XAI-Analysen in personalisierte Gesundheitsassistenzsysteme integrieren.

Schlüsselwörter: Precision Prevention – Explainable Artificial Intelligence – Kennzahlensystem – Ressourcen – Risikofaktoren

Einleitung

Gesellschaftliche, politische und ökonomische Rahmenbedingungen haben sich in den letzten Jahren spürbar verändert. Demografischer Wandel, Fach- und Arbeitskräftemangel, Digitalisierung, zunehmende Flexibilisierung der Arbeit sowie geopolitische und wirtschaftliche Krisen sorgen dafür, dass Unternehmen unter hohem Anpassungsdruck stehen und vorhandene Ressourcen möglichst gezielt einsetzen müssen (Dindarian 2024). Vor diesem Hintergrund rückt die Gesundheit der Beschäftigten noch stärker in den Fokus betrieblicher Strategien, da sie eine zentrale Voraussetzung für Leistungsfähigkeit, Innovationskraft und Wettbewerbsfähigkeit der Unternehmen darstellt (Park et al. 2021).

Betriebliches Gesundheitsmanagement (BGM) hat sich in vielen Unternehmen als umfassender Ansatz etabliert, der unter anderem darauf abzielt, Strukturen, Prozesse und Maßnahmen im Unternehmen so zu gestalten, dass Arbeit langfristig gesundheitserhaltend und gesundheitsförderlich wirkt (Siegel et al. 2021). Im BGM zeigt der innovative Ansatz Precision Prevention neue Möglichkeiten auf, möglichst ganzheitliche Daten in einem zyklischen Prozess aus Bedarfs-erhebung, Datenanalyse und maßgeschneiderten Interventionen so zu verknüpfen, dass Beschäftigte idealerweise passgenau mit der für sie richtigen Maßnahme zur richtigen Zeit und am geeigneten Ort erreicht werden (Blaschke et al. 2024; Mess et al. 2024). Insbesondere datengetriebene Verfahren wie Methoden der Künstlichen Intelligenz (KI) können Verantwortliche im BGM dabei unterstützen, komplexe Muster in Gesundheits- und Arbeitsdaten zu identifizieren und Entscheidungsprozesse im BGM zu präzisieren (Mess et al. 2024).

Ganzheitliche Kennzahlensysteme im BGM

Vor diesem Hintergrund liegt der Fokus im BGM auf Kennzahlen, die BGM-Verantwortliche im Rahmen des Gesundheits-Controllings nutzen, um gesundheitliche Belastungen, Ressourcen und Wirkungen systematisch abzubilden (Treier 2023). Neben einer Vielzahl anderer Kennzahlenmodelle stellt das Treiber-Indikatoren-Modell eine verbreitete Systematisierung dar, die Kennzahlen nach ihrer zeitlichen und kausalen Wirkung unterscheidet und so eine strukturierte Steuerung präventiver Maßnahmen ermöglicht (Uhle u. Treier 2019). Treiberkennzahlen bilden dabei beeinflussbare Voraussetzungen und Ressourcen ab, etwa Qualifikationen, Führungshandeln oder Gesundheitskompetenz (Wellmann 2018). Frühindikatoren erfassen darauf aufbauend erste Veränderungen im Gesundheits- oder Be-

lastungsgeschehen, beispielsweise die wahrgenommene Beanspruchung oder die Arbeitsfähigkeit der Beschäftigten. Spätindikatoren spiegeln schließlich nachgelagerte gesundheitliche und organisationale Folgen wider, etwa Arbeitsunfähigkeitstage (AU-Tage), Erwerbsminderungen oder Fluktuation.

Treiberkennzahlen

In der betrieblichen Praxis stehen auf Ebene der Treiber insbesondere personale und organisationale Belastungen oder Ressourcen im Fokus und bilden zentrale Voraussetzungen für gesundheitsbezogenes Verhalten sowie die Wirksamkeit von Präventionsmaßnahmen. Eine Schlüsselrolle kommt hierbei der Gesundheitskompetenz zu. Sie bestimmt, ob Beschäftigte Gesundheitsinformationen finden, verstehen, bewerten und in gesundheitsförderliches Handeln überführen können (Sørensen et al. 2012; Güttler u. Kohls 2022). Als Treiberkennzahl ist Gesundheitskompetenz besonders relevant, da sie vorgelagert zu gesundheitlichen Outcomes wirkt und zugleich durch organisationale Rahmenbedingungen, Führung und Qualifizierungsmaßnahmen gezielt beeinflussbar ist.

Da sich gesundheitsrelevante Anforderungen je nach Setting erheblich unterscheiden, gewinnt für die Ableitung passgenauer Präventionsmaßnahmen eine domänenspezifische Ausdifferenzierung der Gesundheitskompetenz an Bedeutung (Atanasova u. Kamin 2022). Arbeitsbezogene Gesundheitskompetenz beschreibt im betrieblichen Kontext das Wissen, die Fähigkeiten und die Motivation, gesundheitsrelevante Informationen im Arbeitsalltag zu finden, zu verstehen und anzuwenden (Friedrich et al. 2022). Konzeptionell umfasst sie einen wissens- und fähigkeitsbezogenen Umgang mit arbeitsbezogenen Gesundheitsinformationen sowie eine gesundheitsbezogene Handlungsbereitschaft und Verantwortungsübernahme am Arbeitsplatz (Friedrich et al. 2023). Auf individueller Ebene kann sie fundierte Entscheidungen zur Erhaltung der Arbeitsfähigkeit unterstützen und zugleich die Wirkung organisationaler Maßnahmen wie gesundheitsorientierte Führung oder Partizipation erklären und verstärken (Friedrich et al. 2024).

Frühindikatoren

Ein zentraler Frühindikator ist die Arbeitsfähigkeit. Sie beschreibt, inwieweit Beschäftigte aktuell und perspektivisch in der Lage sind, ihre Arbeit unter Berücksichtigung gesundheitlicher Voraussetzungen und arbeitsbezogener Anforderungen zu bewältigen. Arbeitsfähigkeit fungiert damit im BGM-Kennzahlensystem als integrative Zielgröße,

die individuelle Ressourcen mit arbeitsbezogenen Anforderungen und organisationalen Rahmenbedingungen verknüpft. Somit liefert die Arbeitsfähigkeit belastbare Hinweise auf präventive Handlungsbedarfe und ermöglicht eine priorisierte Planung, Umsetzung und Evaluation betrieblicher Gesundheitsmaßnahmen, was sich beispielsweise durch die konsistenten Zusammenhänge mit relevanten Spätindikatoren wie Krankenstand oder Frühverrentung zeigt (Jungkunz et al. 2023; Magnavita et al. 2024). Damit stellt die Arbeitsfähigkeit die konzeptionelle und empirische Verbindung zwischen Treiberkennzahlen und Spätindikatoren her. Durch diese Bindegliedfunktion verdeutlicht die Arbeitsfähigkeit die besondere Relevanz von Frühindikatoren.

Ein weiterer relevanter Frühindikator ist die gesundheitsbezogene Lebensqualität, die in verschiedenen empirischen Studien in Regressionsanalysen moderate Zusammenhänge mit der Arbeitsfähigkeit zeigt (Ebener u. Hasselhorn 2019; Mokarami et al. 2022). Die gesundheitsbezogene Lebensqualität umfasst ein breiteres Gesundheitsverständnis über alle Lebensbereiche hinweg als multidimensionales Konstrukt, das eine körperliche Komponente, die physisches Leistungsvermögen und funktionale Einschränkungen widerspiegelt, sowie eine mentale Komponente, die emotionales Wohlbefinden, Vitalität, Stressbelastung und mentale Erschöpfung erfasst (Wirtz et al. 2018). Beide Dimensionen gelten als sensible Frühindikatoren, da Verschlechterungen häufig auftreten, bevor manifeste Erkrankungen oder erhöhte Fehlzeiten sichtbar werden (Wellmann 2018).

Spätindikatoren

Spätindikatoren wie AU-Tage stehen in der betrieblichen Praxis häufig im Fokus, da sie meist leicht verfügbar sind und unmittelbar mit Produktivitätsverlusten sowie direkten und indirekten Kosten verbunden sind. AU-Tage bezeichnen die Anzahl der Kalendertage, an denen Beschäftigte aufgrund einer ärztlich attestierten Erkrankung ihre Arbeitsleistung nicht erbringen können (Baumgardt u. Klawisch 2025). Für eine präventive Steuerung des BGM ist ihre Aussagekraft jedoch begrenzt, da sie gesundheitliche Beeinträchtigungen erst abbilden, wenn diese bereits eingetreten sind (Baumgardt u. Klawisch 2025). Gleichwohl ermöglichen AU-Tage als etablierter retrospektiver Indikator des Krankheitsgeschehens auch bei subjektiver Erfassung eine valide Einordnung gesundheitlicher Belastungen und fungieren als verlässlicher Spätindikator (Stapelfeldt et al. 2012). Eine eigene Darstellung eines Treiber-Indikatoren-Modells ist in ➔ **Abb. 1** zu finden.

In der betrieblichen Praxis dominieren häufig Kennzahlensysteme mit Fokus auf Spätindikatoren (Zwetsloot et al. 2020). Für eine vorausschauende und wirksame Steuerung des BGM ist jedoch eine stärkere Berücksichtigung von Treiber- und Frühindikatoren erforderlich (Zwetsloot et al. 2020). Die Literatur zeigt, dass insbesondere die arbeitsbezogene Gesundheitskompetenz bislang kaum als Trei-




Abb. 1: Eigene Darstellung eines Treiber-Indikatoren-Modells nach Treier (2023) und Uhle u. Treier (2019). Fettgedruckte Merkmale wurden in die Analyse einbezogen (Arbeitsunfähigkeitstage wurden subjektiv und retrospektiv erhoben)

Fig. 1: Own illustration of a driver-indicator model based on Treier (2023) and Uhle and Treier (2019). Bolded features were included in the analysis (days of work incapacity were assessed subjectively and retrospectively)

berkennzahl im BGM genutzt wird, obwohl sie entscheidend dafür ist, ob Präventionsmaßnahmen verstanden, genutzt und nachhaltig in den Arbeitsalltag integriert werden (Farantos u. Dounias 2024; Bhatt 2025; Sakai et al. 2026). Eine zentrale Rolle kommt zudem der Arbeitsfähigkeit zu, da sie als sensibler Frühindikator den Erhalt der Beschäftigungsfähigkeit abbildet und als vermittelnde Größe zwischen individuellen und organisationalen Bedingungen sowie späteren gesundheitlichen Outcomes fungiert.

Einsatz von Künstlicher Intelligenz

Neben der gezielten Auswahl von Kennzahlen kann auch deren datenbasierte Analyse einen wesentlichen Beitrag zur strategischen Steuerung und zur Wirksamkeitsbewertung von Gesundheitsförderungsmaßnahmen leisten. Insbesondere Verfahren der Künstlichen Intelligenz (KI) eröffnen neue Möglichkeiten, komplexe Zusammenhänge zwischen Gesundheitskompetenz, Arbeitsfähigkeit und betrieblichen Rahmenbedingungen sichtbar zu machen (Moll 2022). Zudem gewinnen KI-basierte Analysen zunehmend an Bedeutung, um der wachsenden Verfügbarkeit von Gesundheits-, Personalmanagement- und Unternehmensdaten gerecht zu werden und komplexe Wechselwirkungen sowie Einflussstrukturen datenbasiert abzubilden. Moderne KI-Methoden, insbesondere maschinelles Lernen und Deep-Learning-Ansätze, ermöglichen es, nichtlineare Beziehungen zwischen einer Vielzahl von Einflussfaktoren und gesundheitlichen sowie ökonomischen Outcomes zu identifizieren (Shah u. Mishra 2024). In der Entwicklung und Implementierung von Kennzahlensystemen könnten KI-Technologien dazu beitragen, relevante Gesundheitsdaten in Echtzeit zu erfassen, die Wirksamkeit von Präventionsmaßnahmen zu messen und auf dieser Basis individuelle sowie organisationale Handlungsempfehlungen abzuleiten, um die Effektivität und Effizienz von Arbeitsschutz- und Gesundheitsförderungsmaßnahmen zu steigern (Virgillito u. Ledda 2026).

Aus einem Review zum Einsatz von KI im BGM geht hervor, dass solche Methoden bislang vor allem bei Risikovorhersagen oder bei individualisierten Verhaltensinterventionen eingesetzt werden (Lange et al. 2024). Das Review belegt zudem, dass KI-Anwendungen im BGM insgesamt noch selten sind. Darüber hinaus wird betont, dass die Nutzung von KI im BGM-Kontext mit Herausforderungen verbunden ist, da die Einführung solcher Technologien häufig auf Widerstand stößt, insbesondere wenn Beschäftigte nicht ausreichend über die Funktionsweise der KI-Systeme sowie über den Umgang mit sensiblen personenbezogenen Daten und Datenschutzaspekte informiert sind (Virgillito u. Ledda 2026). Daher sind eine umfassende Schulung, transparente Kommunikation und die Einbindung der Belegschaft essenziell, um den verantwortungsvollen Einsatz von KI sowie deren Akzeptanz im BGM sicherzustellen.

Eng damit verknüpft ist die Frage, wie KI-basierte Systeme im BGM gestaltet sein müssen, damit sie nicht nur präzise Vorhersagen liefern, sondern auch für Verantwortliche, Führungskräfte und Beschäftigte nachvollziehbar bleiben. Zudem sollten sie anschlussfähig für die tägliche Arbeit und die Entscheidungsfindung der Verantwortlichen zur Ausgestaltung des BGM bleiben. Der Ansatz der Erklärbaren Künstlichen Intelligenz (Explainable Artificial Intelligence, XAI) setzt an den Punkten der Nachvollziehbarkeit der Ergebnisse zur Unterstützung an. Er zielt darauf ab, die Entscheidungslogik komplexer Modelle transparent zu machen und die wesentlichen Einflussfaktoren für ein bestimmtes Ergebnis verständlich zu kommunizieren (Hulsen 2023). Für das BGM bedeutet dies, dass KI-Modelle künftig nicht nur abstrakte Risiken prognostizieren können, sondern konkrete Anhaltspunkte liefern, welche Faktoren dabei eine zentrale Rolle spielen. Wie ein solcher Ansatz im arbeitsbezogenen Gesundheitskontext umgesetzt werden kann, zeigen exemplarisch die Ergebnisse zu muskuloskelettalen Beschwerden bei Beschäftigten in der Produktion der Automobilbranche (Mollaei et al. 2022). Durch den Einsatz von XAI auf Basis von SHapley Additive exPlanations (SHAP) ermöglichen die Modelle nicht nur präzise Prognosen zum Schweregrad von Beschwerden oder zu bevorstehenden medizinischen Terminen, sondern machen zugleich transparent, welche beruflichen Belastungen, Arbeitsbedingungen, betroffenen Körperregionen und funktionalen Einschränkungen maßgeblich zu den Vorhersagen beitragen. Die skizzierte Studie verdeutlicht eindrucksvoll das Potenzial von XAI, arbeitsbezogene Gesundheitsdaten so aufzubereiten, dass sowohl präzise Prognosen als auch handlungsrelevante Erklärungen sowie passgenaue Maßnahmen für unterschiedliche betriebliche Akteursgruppen bereitgestellt werden können. Obwohl XAI-Analysen grundsätzlich auch auf Outcomes der mentalen Gesundheit am Arbeitsplatz übertragbar sind (Mokheleli et al. 2025), ist ihre praktische Anwendung bislang nur punktuell untersucht. Zusammenfassend geht aus einem Review hervor, dass vorliegende Studien meist einzelne Berufsgruppen fokussieren und Kennzahlen häufig nicht systematisch im Rahmen theoriegeleiteter Modelle berücksichtigen (Mess et al. 2024).

Zielstellungen

Vor dem Hintergrund der skizzierten Forschungsdesiderate auf inhaltlicher und methodischer Ebene sowie der zunehmenden Anforderungen an ganzheitliche und strategieleitende Kennzahlensysteme im BGM verfolgt diese Studie das Ziel, die Bedeutung

der Treiberkennzahlen der allgemeinen und arbeitsbezogenen Gesundheitskompetenz sowie der XAI-Analysen für die Vorhersage der Arbeitsfähigkeit zu untersuchen. In einer ersten Zielstellung soll untersucht werden, welchen relativen Beitrag die Treiber arbeitsbezogene und allgemeine Gesundheitskompetenz im Vergleich zu etablierten Früh- und Spätindikatoren (gesundheitsbezogene Lebensqualität, AU-Tage) zur Vorhersage der Arbeitsfähigkeit leisten. Dadurch soll aufgezeigt werden, in welchem Ausmaß Gesundheitskompetenz neben etablierten Indikatoren als eigenständige Stellgröße in einem ganzheitlichen BGM-Kennzahlensystem zu verorten ist und wie sie zur datenbasierten Ableitung passgenauer Maßnahmen beitragen kann.

In einer zweiten Zielstellung soll exemplarisch dargestellt werden, wie XAI-Analysen auf individueller Ebene eingesetzt werden können, um die Relevanz einzelner Risiko- oder Schutzfaktoren für die Ausprägungen kritischer beziehungsweise unkritischer Arbeitsfähigkeit sichtbar zu machen. Anhand eines KI-basierten Modells werden individuelle Profile berechnet und mittels XAI-Analysen aufbereitet, so dass für BGM-Verantwortliche nachvollziehbar wird, welche Variablen im Einzelfall besonders stark zum vorhergesagten Risiko für die Arbeitsfähigkeit der Einzelperson beitragen. Dadurch soll illustriert werden, wie personalisierte Rückmeldungen gestaltet werden können, die sowohl BGM-Verantwortliche als auch Beschäftigte bei der Planung und Priorisierung von Maßnahmen unterstützen und dabei eine hohe Transparenz und Nachvollziehbarkeit der Ergebnisse wahren.

Methoden

Studiendesign und Stichprobe

Die vorliegende Untersuchung basiert auf einer querschnittlichen Online-Befragung, die in Kooperation mit einem externen Marktforschungsunternehmen durchgeführt wurde. Vor Beginn der Studie wurde ein Ethikantrag bei der Ethikkommission der Technischen Universität München (2025-113-NM-BA) eingereicht und positiv beschieden. Alle Teilnehmenden wurden vorab über Ziel, Inhalt und Datenschutz der Studie informiert und erteilten ihre Einwilligung. Die Datenerhebung erfolgte vom 09.12.2025 bis zum 06.01.2026. Der Median der Bearbeitungszeit des Online-Fragebogens betrug 15 Minuten.

Insgesamt nahmen zunächst $N = 2000$ Personen an der Befragung teil. Zur Identifikation multivariater Ausreißer wurde eine Ausreißeranalyse auf Basis der Mahalanobis-Distanz durchgeführt (Li et al. 2019). Hierfür wurden die ausgewählten zentralen Variablen der Studie herangezogen. Auf dieser Grundlage wurden drei Fälle als multivariate Ausreißer identifiziert und aus den weiteren Analysen ausgeschlossen. Die finale Stichprobe umfasste somit $n = 1997$ Personen. Alle Befragten waren erwerbstätig: 78,1 % in Vollzeit, 20,2 % in Teilzeit und 1,7 % in geringfügiger Beschäftigung. Das Durchschnittsalter der Teilnehmenden betrug $M = 43,7$ Jahre ($SD = 13,1$; Median = 43,0) mit einer Altersspanne von 18 bis 69 Jahren. Hinsichtlich der subjektiven Zuordnung zur Variable Geschlecht verteilte sich die Stichprobe nahezu gleichmäßig auf weibliche Personen (49,9 %) und männliche Personen (50,0 %); 0,1 % identifizierten sich mit einem diversen Geschlecht. In der Stichprobe wiesen 20 % einen niedrigen, 57 % einen mittleren und 23 % einen hohen

sozioökonomischen Status (SES) auf. Bezüglich der Branchenzugehörigkeit der Teilnehmenden wurde die Stichprobensummenproportional an die Branchenverteilung der Beschäftigten in Deutschland nach den Angaben des Statistischen Bundesamts (2026) angepasst: 33 % Öffentliche und sonstige private Dienstleistungen (mit Erziehung, Gesundheit), 22 % Handel, Verkehr und Gastgewerbe, 21 % Sonstige Dienstleistungsbereiche wie Information und Kommunikation, Finanz- und Versicherungsdienstleistung, Grundstücks- und Wohnungswesen, Unternehmensdienstleistung, 20 % Produzierendes bzw. verarbeitendes Gewerbe mit Baugewerbe und 1 % Land- und Forstwirtschaft.

Messinstrumente

Der SES wurde anhand des etablierten Indexes des Robert Koch-Instituts erfasst, der auf Bildung, berufliche Stellung und Einkommen basiert und in die Bereiche niedriger, mittlerer und hoher SES eingeteilt wird (Müters et al. 2023). Die allgemeine Gesundheitskompetenz wurde mit der Kurzversion des European Health Literacy Survey Questionnaire (HLS-EU-Q16) erfasst (Röthlin et al. 2013; Pelikan et al. 2019). Auf einer Skala von 1 (sehr einfach) bis 4 (sehr schwierig) wurden Fragen zur subjektiven Einschätzung des Findens, Verstehens, Beurteilens und Anwendens allgemeiner Gesundheitsinformationen gestellt. Die arbeitsbezogene Gesundheitskompetenz wurde mithilfe des entwickelten Instruments zur domänenspezifischen Gesundheitskompetenz am Arbeitsplatz gemessen (Friedrich et al. 2023). Zwei Faktoren umfassen den wissens- und fähigkeitsbasierten Umgang mit arbeitsbezogenen Gesundheitsinformationen sowie die Bereitschaft und Verantwortungsübernahme für Gesundheit am Arbeitsplatz (Friedrich et al. 2022). Der erste Faktor wurde auf einer Skala von 1 (sehr einfach) bis 4 (sehr schwierig), der zweite Faktor mittels Zustimmung zu einer 4-stufigen Skala von „trifft überhaupt nicht zu“ bis „trifft vollkommen zu“ erfragt. Die allgemeine und arbeitsbezogene Gesundheitskompetenz wurde anhand etablierter Kategoriensysteme interpretiert, die die Ausprägungen von inadäquat (< 25 Punkte) beziehungsweise problematisch (25 bis < 33 Punkte) bis hin zu ausreichend (> 33 bis < 42 Punkte) und exzellent (> 42 Punkte) klassifizieren. Die Zuordnung der im Beitrag dargestellten Beispielperson zu den jeweiligen Ausprägungen (z. B. „niedrig“, „hoch“, „exzellent“) erfolgte ausschließlich auf Basis dieser Skalenklassifikation und nicht relativ zu stichprobenspezifischen Kennwerten wie Mittelwerten. Die gesundheitsbezogene Lebensqualität wurde mit der Short Form 12 Version 2 (SF-12v2) erfasst, die mit getrennten Scores für die physische und die mentale Komponente Aussagen über den Gesundheitszustand der Befragten liefert (Wirtz et al. 2018; Drixler et al. 2020). Die Arbeitsfähigkeit wurde mithilfe des Work Ability Index (WAI) erfasst. Der WAI ist ein international etabliertes Instrument zur Erfassung der aktuellen und zukünftigen Arbeitsfähigkeit hinsichtlich der Arbeitsanforderungen und gesundheitlicher Einschränkungen, mit den Kategorien kritische, mäßige, gute und sehr gute Arbeitsfähigkeit (Hasselhorn u. Freude 2007). AU-Tage wurden mittels subjektiver Rückmeldungen retrospektiv erfasst, was durch andere Studien als gängiges und reliables Vorgehen belegt wurde (Voss et al. 2008; Ebener u. Hasselhorn 2019). Die Beschäftigten gaben in fünf Kategorien an, wie viele Arbeitstage sie im vergangenen Jahr aufgrund gesundheitlicher Probleme gefehlt haben: überhaupt keinen Tag, höchstens 9 Tage, 10–24 Tage, 25–99 Tage oder 100–365 Tage.

Datenanalyse

Zur Analyse und zur Sicherstellung der Transparenz und Interpretierbarkeit der Modelle kamen XAI-Methoden zum Einsatz. Zur Vorhersage der Arbeitsfähigkeit wurde ein Random-Forest-Regressionsmodell implementiert. Random Forests ermöglichen die Modellierung nichtlinearer Zusammenhänge sowie von Interaktionseffekten zwischen den Prädiktoren. Zur Evaluation der Modellgüte wurde ein zufälliger 80/20-Train-Test-Split verwendet, wobei 80 % der Daten für das Training und 20 % für die unabhängige Testung verwendet wurden. Die Modellgüte wurde anhand des Mean Absolute Error (MAE), des Root Mean Squared Error (RMSE) und des Bestimmtheitsmaßes R^2 beurteilt. Konkret wurden SHapley Additive exPlanations (SHAP)-Werte berechnet, um den Beitrag einzelner Prädiktoren zu den modellbasierten Vorhersagen auf individueller Ebene zu quantifizieren. Insbesondere erlauben SHAP im Vergleich zu klassischen Regressionsanalysen eine modellunabhängige, nichtlineare und individuelle Quantifizierung der Beiträge einzelner Prädiktoren zu den Vorhersagen und machen damit komplexe Zusammenhänge, unter anderem auf Einzelfallebene, nachvollziehbar. Die globale Variablenwichtigkeit wurde anhand der SHAP-Werte bestimmt. Hierzu wurde für jeden Prädiktor der durchschnittliche absolute Einfluss auf die Modellvorhersagen über alle Beobachtungen hinweg berechnet und anschließend ins Verhältnis zur Gesamtsumme der Einflüsse aller Variablen gesetzt. Dadurch ergibt sich eine relative Wichtigkeit der einzelnen Merkmale, die angibt, wie stark ein Prädiktor im Mittel zur Veränderung der Modellvorhersage beiträgt. Insgesamt konnten dadurch sowohl globale Einflussfaktoren als auch individuelle Risiko- und Ressourcenprofile nachvollziehbar dargestellt werden. Neben dem Random-Forest-Regressionsmodell zur Vorhersage des kontinuierlichen WAI wurde ein separates Random-Forest-Klassifikationsmodell zur Schätzung der Wahrscheinlichkeit einer kritischen Arbeitsfähigkeit („kritisch“ vs. „nicht kritisch“) trainiert. Die dargestellten Wahrscheinlichkeiten und Wenn-dann-Szenarien zur Vorhersage der Auswirkungen von Veränderungen bestimmter Merkmale basieren auf diesem Klassifikationsmodell. Für die exemplarische Darstellung lokaler SHAP-Profile wurde jeweils eine Person aus dem Testdatensatz ausgewählt, deren Arbeitsfähigkeit bzw. modellierte Risikowahrscheinlichkeit dem Mittelwert der jeweiligen Trainingsstichprobe am nächsten lag.

Ergebnisse

Die deskriptiven Statistiken der untersuchten Variablen sind in **→ Tabelle 1** dargestellt. Die AU-Tage wurden in fünf Kategorien mit einem Median von 2 erfasst, das heißt, kumuliert hatten 70 % der Befragten höchstens neun Fehltage pro Jahr. Weitere 20 % der Befragten hatten weniger als 25 Fehltage. Nur 7 % der Befragten hatten 25 bis 99 Fehltage beziehungsweise 3 % hatten mehr als 100 Fehltage.

Prädiktive Modellierung der Arbeitsfähigkeit

Zur Analyse der Zusammenhänge zwischen Treibern, Früh- und Spätindikatoren wurde ein KI-basiertes Modell zur Vorhersage der Arbeitsfähigkeit trainiert. Berücksichtigt wurden soziodemografische Faktoren (Alter, Geschlecht, sozioökonomischer Status), allgemeine und arbeitsbezogene Gesundheitskompetenz, die physische und

Tabelle 1 Mittelwerte (M), Standardabweichungen (SD) und Korrelationen sowie Konfidenzintervalle der untersuchten Merkmale
 Table 1: Means (M), standard deviations (SD), correlations, and confidence intervals of the examined characteristics

Variable	M	SD	1	2	3	4	5	6	7	8	9
1. Alter	43,71	13,09									
2. Geschlecht			-0,10** [-0,14; -0,05]								
3. SES	14,74	3,55	-0,11** [-0,15; -0,06]	-0,06** [-0,11; -0,02]							
4. OHL F1	30,00	10,25	0,03 [-0,01; 0,07]	-0,07** [-0,12; -0,03]	0,09** [0,04; 0,13]						
5. OHL F2	30,08	10,61	0,04 [-0,01; 0,08]	-0,07** [-0,12; -0,03]	0,06** [0,02; 0,11]	0,42** [0,38; 0,45]					
6. HL	31,57	8,65	0,12** [0,07; 0,16]	-0,04 [-0,08; 0,01]	0,14** [0,09; 0,18]	0,71** [0,69; 0,73]	0,34** [0,30; 0,38]				
7. PCS	46,45	7,41	-0,05* [-0,09; -0,00]	-0,07** [-0,11; -0,02]	0,14** [0,10; 0,18]	0,22** [0,18; 0,26]	0,07** [0,02; 0,11]	0,22** [0,18; 0,26]			
8. MCS	45,09	9,41	0,22** [0,18; 0,26]	-0,15** [-0,20; -0,11]	0,08** [0,04; 0,13]	0,32** [0,28; 0,36]	0,13** [0,09; 0,17]	0,32** [0,28; 0,36]	0,63** [0,60; 0,65]		
9. WAI	36,71	7,70	-0,03 [-0,07; 0,02]	-0,10** [-0,15; -0,06]	0,16** [0,12; 0,21]	0,31** [0,27; 0,35]	0,13** [0,09; 0,18]	0,28** [0,24; 0,32]	0,71** [0,69; 0,73]	0,69** [0,66; 0,71]	
10. AU	2,10	1,02	-0,02 [-0,06; 0,03]	0,03 [-0,01; 0,08]	-0,07** [-0,11; -0,03]	-0,12** [-0,16; -0,08]	-0,01 [-0,05; 0,04]	-0,08** [-0,13; -0,04]	-0,41** [-0,45; -0,38]	-0,35** [-0,38; -0,31]	-0,55** [-0,58; -0,52]

Anmerkungen. SES = Sozioökonomischer Status, OHL F1 = Wissens- und fähigkeitsbasierter Umgang mit Gesundheitsinformationen der arbeitsbezogenen Gesundheitskompetenz (OHL), OHL F2 = Bereitschaft und Verantwortungsübernahme für Gesundheit am Arbeitsplatz der arbeitsbezogenen Gesundheitskompetenz (OHL), HL = Allgemeine Gesundheitskompetenz, PCS = Physical Component Score für körperliche Gesundheit, MCS = Mental Component Score für mentale Gesundheit, WAI = Work Ability Index, AU = Arbeitsunfähigkeitstage pro Jahr in Kategorien. * $p < 0,05$, ** $p < 0,01$

mentale gesundheitsbezogene Lebensqualität sowie Arbeitsunfähigkeitstage. Zur Interpretation der Modelleffekte wurden SHAP-Werte herangezogen. Diese zeigen, wie stark einzelne Merkmale die Vorhersage der Arbeitsfähigkeit beeinflussen: Je höher der mittlere

absolute SHAP-Wert, desto größer ist der durchschnittliche Einfluss auf das Outcome (Salih et al. 2025).

Die aggregierten Analysen (Abb. 2) zeigten deutlich, dass die physische Lebensqualität der stärkste Prädiktor war (mittlerer




Abb. 2: Relative Bedeutung der Einflussfaktoren für das Vorhersagemodell, dargestellt anhand der mittleren absoluten SHAP-Werte (SHapley Additive exPlanations). Höhere SHAP-Werte kennzeichnen einen stärkeren Beitrag der jeweiligen Variable zur Modellvorhersage. Die Variablen sind entsprechend ihrer mittleren Bedeutung für die Modellvorhersage absteigend geordnet

Fig. 2: Relative importance of the factors influencing the prediction model, shown using mean absolute SHAP values (SHapley Additive exPlanations). Higher SHAP values indicate a stronger contribution of the respective variable to the model prediction. The variables are ordered in descending order of their mean importance to the model prediction.

SHAP-Wert = 2,5) und 32 % der gesamten SHAP-basierten Modellbedeutung ausmachte. Diese 32 % bedeuten, dass rund ein Drittel aller Entscheidungsbeiträge (rechnerischen Einflüsse, mit denen einzelne Merkmale die Vorhersage der Arbeitsfähigkeit nach oben oder unten verschieben) des Modells auf Unterschiede in der physischen Lebensqualität zurückzuführen war. Dahinter folgten die mentale Lebensqualität (2,3; 30 %) und die AU-Tage (1,3; 16 %). Konkret bedeutet dies: Eine bessere körperliche oder mentale Lebensqualität geht mit deutlich höheren prognostizierten WAI-Werten einher, eine schlechtere mit niedrigeren (ca. $\pm 2-3$ Punkte auf der Skala). Darüber hinaus zeigten der wissens- und fähigkeitsbasierte Faktor der arbeitsbezogenen Gesundheitskompetenz (0,4) sowie die allgemeine Gesundheitskompetenz (0,3) relevante, wenn auch schwächere Einflüsse auf die Arbeitsfähigkeit. Das Alter (0,4) und der sozioökonomische Status (0,3) hatten eine ähnliche Bedeutung. Geringere Einflüsse fanden sich für die Handlungsbereitschaft und Verantwortungsübernahme der arbeitsbezogenen Gesundheitskompetenz (0,2) sowie für das Geschlecht (0,1). Die Analysen liefern konkrete Anhaltspunkte für prioritäre, evidenzbasierte Interventionsfelder im BGM,

mit besonderem Fokus auf Lebensqualität und Gesundheitskompetenzen als die stärksten und zugleich veränderbaren Prädiktoren der Arbeitsfähigkeit. Die Modellgüte des Random-Forest-Modells war insgesamt gut. Das Modell erreichte auf dem unabhängigen Testdatensatz ein R^2 von 0,63, ein MAE von 3,5 und ein RMSE von 4,5, was auf eine substanzielle Vorhersagekraft bei gleichzeitig moderaten Vorhersagefehlern hinweist.

Lokale Erklärungen und individuelle Risikoprofile

Neben aggregierten Analysen wurden lokale SHAP-Profile erstellt, um individuelle Einflussfaktoren sichtbar zu machen. Beispielhaft wurde eine im Gastgewerbe tätige 56-jährige Frau mit hohem sozioökonomischem Status und mäßiger Arbeitsfähigkeit (WAI = 29,0) betrachtet, deren prognostizierter Wert nahe am Stichprobenmittel lag. Für diese Person erwies sich eine niedrige physische Lebensqualität (34,9 im Vergleich zum Mittelwert der Stichprobe $M = 46,5$) als zentraler Risikofaktor, während eine ausreichende arbeitsbezogene Gesundheitskompetenz (37,5 im Vergleich zu $M = 30,0$) und eine exzellente allgemeine Gesundheitskompetenz (44,8 im Vergleich zu $M = 31,6$) als Schutzfaktoren wirkten. Der lokale SHAP-Plot (→ Abb. 3) zeigt, wie einzelne Prädiktoren zur Vorhersagewahrscheinlichkeit einer kritischen Arbeitsfähigkeit für diese Person beitragen. Das Beispiel verdeutlicht den praktischen Nutzen von XAI: Trotz vorhandener Kompetenzen stellen Einschränkungen der Lebensqualität die wichtigsten Ansatzpunkte für präventive Maßnahmen dar.

Wenn-dann-Szenarien zur Unterstützung bei der Auswahl von Gesundheitsförderungsmaßnahmen

Zur weiteren Veranschaulichung der praktischen Nutzbarkeit für das BGM wurden Wenn-dann-Szenarien erstellt. Ausgangspunkt war die 56-jährige Frau, deren modellbasierte Wahrscheinlichkeit für eine kritische Arbeitsfähigkeit bei 14 % lag. Simulierte Verbesserungen der physischen und mentalen Lebensqualität sowie der arbeitsbezogenen Gesundheitskompetenz um jeweils 5 Punkte führten zu einer Reduktion des Risikos für eine kritische Arbeitsfähigkeit auf 4 %. Dies verdeutlicht das Potenzial von XAI-gestützten Modellen zur Simulation möglicher Interventionseffekte.

Diskussion

Zusammenfassung der zentralen Befunde

In Bezug auf die erste Zielstellung unterstreichen die Ergebnisse die zentrale Bedeutung gesundheitsbezogener Ressourcen für die Arbeitsfähigkeit. Die aggregierten SHAP-Analysen zeigen, dass insbesondere die physische und mentale gesundheitsbezogene Lebensqualität eng mit der Arbeitsfähigkeit verknüpft sind. Diese Befunde stehen im Einklang mit der bisherigen Forschung (Mokarami et al. 2022) und deuten darauf hin, dass Einschränkungen der Lebensqua-




Abb. 3: Lokale SHAP-Analyse der Einflussfaktoren auf die Wahrscheinlichkeit kritischer Arbeitsfähigkeit einer Beispielperson. Anmerkung: Positive SHAP-Werte erhöhen die vorhergesagte Wahrscheinlichkeit einer kritischen Ausprägung, während negative SHAP-Werte sie senken. Die Länge der Balken verdeutlicht die Stärke des jeweiligen Einflusses
Fig. 3: Local SHAP analysis of the factors influencing the probability of critical work ability for a sample individual. Note: Positive SHAP values increase the predicted probability of a critical outcome, while negative SHAP values decrease it. The length of the bars indicates the magnitude of the respective influence

lität unmittelbar mit einer reduzierten Arbeitsfähigkeit einhergehen und als sensible Indikatoren des aktuellen Funktionsniveaus interpretiert werden können. Entsprechend erweisen sich beide Dimensionen im Vorhersagemodell als die stärksten Prädiktoren und vereinen 62 % der gesamten SHAP-basierten Variablenwichtigkeit (32 % physische Lebensqualität und 30 % mentale Lebensqualität). Zugleich erfassen Arbeitsfähigkeit und gesundheitsbezogene Lebensqualität komplementäre Aspekte des funktionalen Zustands: Während Erstere die Bewältigung arbeitsbezogener Anforderungen fokussiert, bildet Letztere das subjektive gesundheitliche Erleben allgemein ab (Lohela Karlsson et al. 2015). Ihre gemeinsame Berücksichtigung erhöht damit die Aussagekraft prädiktiver Modelle und reduziert das Risiko verzerrter Effekte (Bergman et al. 2020).

Auf diese Prädiktoren folgten die AU-Tage mit einem substanziellen, jedoch geringeren Beitrag zur Vorhersage. Dieses Ergebnis wird durch aktuelle Befunde gestützt, die insbesondere bei beeinträchtigter mentaler Lebensqualität einen Zusammenhang zwischen Arbeitsfähigkeit und AU-Tagen zeigen (Magnavita et al. 2024). Inhaltlich weisen AU-Tage weniger auf frühe Risikokonstellationen als vielmehr auf bereits manifeste gesundheitliche Einschränkungen hin und sind daher primär als reaktiver Spätindikator zu interpretieren. Gleichwohl liefern AU-Tage wichtige Zusatzinformationen und stellen als etablierte Kennzahl eine zentrale Referenzgröße im BGM-Kennzahlensystem dar. In der vorliegenden Studie wurden sie jedoch subjektiv erfasst, was bei der Interpretation der Ergebnisse zu berücksichtigen ist und die

Vergleichbarkeit mit Studien auf Basis objektiver Routinedaten einschränken kann.

Im Vergleich dazu zeigen auf der Ebene der Treiberkennzahlen insbesondere der wissens- und fähigkeitsbasierte Faktor der arbeitsbezogenen Gesundheitskompetenz sowie die allgemeine Gesundheitskompetenz moderat ausgeprägte und mit der aktuellen Literatur konsistente Zusammenhänge zur Arbeitsfähigkeit (Gernert et al. 2022; Friedrich et al. 2024). Auch wenn ihr unmittelbarer Einfluss geringer ausfällt als jener der Lebensqualität oder der AU-Tage, sind sie als potenziell veränderbare Ressourcen von besonderer Bedeutung (Nutbeam u. Lloyd 2021; Kunz u. Millhoff 2023). Gesundheitskompetenzen wirken als vorgelagerte Determinanten, indem sie Beschäftigte befähigen, gesundheitsrelevante Informationen zu nutzen, Belastungen frühzeitig zu erkennen und präventiv zu handeln. Sie fungieren als zentrale präventive Stellgrößen, über die gesundheitsbezogene Entwicklungen frühzeitig beeinflusst und gesteuert werden können (Gernert et al. 2022).

Soziodemografische Faktoren wie Alter und SES weisen ebenfalls moderate, aber inhaltlich gut erklärbare Zusammenhänge mit der Arbeitsfähigkeit auf (Feldt et al. 2009; Rohrbacher u. Hasselhorn 2022). Ein niedriger SES ist mit ungünstigeren Arbeitsbedingungen und geringerer Arbeitsfähigkeit assoziiert, während mit zunehmendem Alter chronische Erkrankungen und funktionelle Einschränkungen häufiger auftreten können. Die moderaten Effekte von Alter und SES verdeutlichen, dass sie als wichtige Kontextfaktoren die Rahmenbedingungen für die Gesundheit der Beschäftigten prägen. Gleichzeitig bieten veränderbare Kennzahlen wie Gesundheitskompetenzen, die sich durch gezielte Maßnahmen direkt beeinflussen lassen, praxisnähere und effektivere Ansatzpunkte für die Gesundheitsförderung (Van Den Berg et al. 2009).

Vor diesem Hintergrund ergibt sich eine zeitliche Logik der Einflussfaktoren: Gesundheitskompetenzen wirken als vorgelagerte Determinanten für die Arbeitsfähigkeit, die wiederum als sensibler Frühindikator aktueller Einschränkungen fungiert. AU-Tage sind primär als Spätindikatoren bereits manifestierter gesundheitlicher Beeinträchtigungen zu interpretieren. Entsprechend zeigten die retrospektiv und subjektiv berichteten AU-Tage im Modell zwar relevante Zusammenhänge, jedoch eher als nachgelagerter Prädiktor der aktuellen Arbeitsfähigkeit. Für das BGM ergibt sich daraus, dass gesundheitsfördernde Interventionen idealerweise nicht erst bei erhöhten Fehlzeiten ansetzen, sondern frühzeitig auf der Ebene von Kompetenzen und Lebensqualität unter Berücksichtigung der Kontextfaktoren implementiert werden sollten.

Die erreichte Modellgüte weist auf eine hohe praktische Relevanz des Random-Forest-Modells hin. Das Modell konnte rund 63 % der Unterschiede in der Arbeitsfähigkeit erklären, was auf eine substanzielle Vorhersagekraft der einbezogenen psychologischen, gesundheitsbezogenen und soziodemografischen Faktoren hinweist. Gleichzeitig zeigen die moderaten Fehlerwerte (MAE = 3,5; RMSE = 4,5), dass die vorhergesagten Arbeitsfähigkeitswerte im Durchschnitt nur um wenige Punkte von den tatsächlich beobachteten Werten abweichen. Dies deutet darauf hin, dass das Modell nicht nur statistisch leistungsfähig ist, sondern auch eine potenziell praxisrelevante Grundlage für die frühzeitige Identifikation von Risikokonstellationen im Kontext von Arbeitsfähigkeit und betrieblicher Gesundheit bieten kann.

Die Ergebnisse der zweiten Zielstellung verdeutlichen, dass die Kombination aus prädiktiver Modellierung und XAI-Verfahren einen konkreten praktischen Mehrwert für individualisierte Präventionsstrategien im BGM bietet. Während aggregierte Analysen zentrale Einflussgrößen auf Gruppenebene identifizieren, ermöglichen lokale SHAP-Profile eine differenzierte Betrachtung auf Einzelfallebene und machen transparent, welche Faktoren im individuellen Kontext als Risiko- beziehungsweise Schutzfaktoren wirken. Dadurch wird die bislang häufig abstrakte Modellvorhersage in konkrete, handlungsrelevante Informationen übersetzt, um daraus zielgerichtete Maßnahmen abzuleiten (Johannssen u. Chukhrova 2025; Yazdipour et al. 2025).

Die exemplarischen Analysen der individuellen Profile zeigen dabei ein konsistentes Muster: Hohe allgemeine und arbeitsbezogene Gesundheitskompetenz wirken als stabilisierende Schutzfaktoren, während reduzierte physische oder mentale Lebensqualität das Risiko einer kritischen Arbeitsfähigkeit deutlich erhöhen. Diese Konstellation unterstreicht die unterschiedliche funktionale Rolle der Faktoren: Lebensqualitätsmaße spiegeln eher den aktuellen Gesundheitszustand wider und fungieren als unmittelbare Risikomarker (Drixler et al. 2020), während Kompetenzen als vorgelagerte Ressourcen zu verstehen sind, die Beschäftigte befähigen, Belastungen zu bewältigen, gesundheitsförderliche Entscheidungen zu treffen und Verschlechterungen frühzeitig zu kompensieren. Entsprechend können hohe Kompetenzwerte negative Effekte eingeschränkter Lebensqualität teilweise abpuffern.

Besonders anschaulich wird dieser Zusammenhang in simulierten Wenn-dann-Szenarien. Die modellbasierte Verbesserung mehrerer veränderbarer Faktoren, etwa eine gleichzeitige Steigerung der physischen und mentalen Lebensqualität sowie der arbeitsbezogenen Gesundheitskompetenz, führt zu einer deutlichen Reduktion des individuellen Risikos kritischer Arbeitsfähigkeit. Dies verdeutlicht, dass Interventionseffekte nicht isoliert, sondern kumulativ wirken und dass kombinierte Maßnahmen einen größeren Nutzen entfalten als Einzelinterventionen. XAI-basierte Simulationen ermöglichen eine quantitative Abschätzung potenzieller Veränderungen der Indikatoren. Damit werden evidenzbasierte Entscheidungen zur Priorisierung von Gesundheitsförderungsmaßnahmen für spezifische Beschäftigte unterstützt. Insbesondere in herausfordernden Zeiten stehen Unternehmen und Verantwortliche vor der Aufgabe, bei begrenzten Ressourcen aus einer Vielzahl von Kennzahlen die relevanten Indikatoren auszuwählen, auszuwerten und Maßnahmen zu priorisieren. XAI-Analysen ermöglichen eine differenzierte und datenbasierte Abbildung von Risiken und Ressourcen und schaffen zugleich Transparenz und Nachvollziehbarkeit, wodurch Führungskräfte und Beschäftigte in die Ableitung und Priorisierung von Gesundheitsmaßnahmen einbezogen werden können (Alkhanbouli et al. 2025).

Darüber hinaus erlaubt der XAI-Ansatz, verschiedene Interventionsszenarien, beispielsweise gezielte Informationen oder Gesundheitsprogramme, datenbasiert zu simulieren und deren voraussichtlichen Effekte auf Arbeitsfähigkeit oder Fehlzeiten miteinander zu vergleichen, um Maßnahmen evidenzbasiert zu priorisieren. So kann beispielsweise geprüft werden, ob eine Verbesserung der Lebensqualität um wenige Punkte einen stärkeren prognostischen Effekt hat als eine isolierte Kompetenzsteigerung

oder ob strukturelle Faktoren wie Arbeitsbedingungen stärker adressiert werden sollten. Durch die Gegenüberstellung solcher Szenarien werden die größten erwartbaren Veränderungen identifiziert und als Entscheidungsgrundlage für gezielte Maßnahmenvorschläge nutzbar gemacht.

Limitationen

Trotz der innovativen Kombination aus prädiktiver Modellierung und XAI-Analysen weist die vorliegende Studie einige Limitationen auf, die bei der Interpretation der Ergebnisse zu berücksichtigen sind. Zunächst ist das querschnittliche Studiendesign ein wesentlicher Einschränkungsfaktor, da keine kausalen Zusammenhänge zwischen Treiberkennzahlen und Frühindikatoren belegt werden können. Die identifizierten Zusammenhänge sind daher als assoziativ zu interpretieren und könnten durch zeitlich vorgelagerte oder nicht erfasste Einflussfaktoren geprägt sein. Dennoch bilden theoriegeleitete und durch frühere Studien fundierte Modellannahmen im BGM-Kontext einen etablierten Ausgangspunkt für empirische Analysen auf Basis querschnittlicher Daten und können die systematische Identifikation relevanter Kennzahlen ermöglichen. Zudem könnten konfigurationsanalytische Ansätze wie die Coincidence Analysis (Whitaker et al. 2020) künftig auch in Querschnittsstudien eingesetzt werden, um mögliche kausale Zusammenhänge zwischen Treiber- und Frühindikatoren systematisch zu untersuchen. Darüber hinaus würde eine prospektive Nachverfolgung der Stichprobe ermöglichen, die Stabilität der SHAP-basierten Prädiktoren über die Zeit zu prüfen und die Vorhersagekraft für tatsächliche Veränderungen der Arbeitsfähigkeit zu testen.

Als weitere Limitation ist zu berücksichtigen, dass die AU-Tage in der vorliegenden Studie auf subjektiven Selbstauskünften der Teilnehmenden basieren und nicht auf objektiv erhobenen Routinedaten. Damit sind potenzielle Erinnerungs- und Einschätzungsbias nicht vollständig auszuschließen. Die Evidenzlage zeigt jedoch, dass subjektiv berichtete AU-Tage in vielen Kontexten eine hinreichende Reliabilität aufweisen und insbesondere für kürzere und mittlere Erkrankungszeiträume gut mit administrativen Daten übereinstimmen (Voss et al. 2008). Einschränkungen der Validität werden in der Literatur vor allem für sehr lange oder komplexe Krankheitsverläufe beschrieben, bei denen es vermehrt zu Rekonstruktionsfehlern kommen kann (Stapelfeldt et al. 2012). Diese Aspekte sollten bei der Interpretation der Ergebnisse entsprechend berücksichtigt werden.

Neben diesen Aspekten ist als weitere Limitation zu berücksichtigen, dass im Rahmen der vorliegenden Studie lediglich ein begrenzter Ausschnitt eines ganzheitlichen BGM-Kennzahlensystems exemplarisch analysiert wurde (Treier 2023). Organisational ausgerichtete Treiberkennzahlen (z. B. Arbeitsbedingungen und Organisationskultur) wurden ebenso wenig berücksichtigt wie organisationale Frühindikatoren (z. B. Vertrauen in die Führungsebene). Auch organisationale Spätindikatoren wie Fluktuationsraten und die Anzahl und Schwere von Arbeitsunfällen sind datenbedingt unberücksichtigt, obwohl sie für die Abbildung eines umfassenden und steuerungsrelevanten BGM-Kennzahlensystems von hoher Bedeutung sind. Die gewählte Vorgehensweise diente primär dazu, die Anwendbarkeit von XAI-Analysen an einem konkreten Set individuumsbezogener Kennzahlen exemplarisch zu illustrieren.

Ein weiterer kritischer Punkt betrifft allgemein die praktische Umsetzung KI-basierter Ansätze im betrieblichen Kontext. Die Integration von XAI-gestützten Modellen in laufende BGM-Prozesse wirft Fragen der Datensouveränität und des ethischen Datenmanagements auf, insbesondere hinsichtlich sensibler personenbezogener Informationen. In Deutschland unterliegen Gesundheitsdaten strengen Vorgaben der Datenschutz-Grundverordnung und des Patientendaten-Schutz-Gesetzes, was die anonymisierte Verarbeitung sowie transparente Einwilligungsprozesse erfordert. Auf Unternehmensebene könnten Datenschutzrisiken entstehen, etwa bei der Speicherung individueller SHAP-Profile. Zudem besteht die Gefahr einer Verzerrungsverstärkung durch unbalancierte Trainingsdaten, etwa bei unterrepräsentierten Branchen oder Altersgruppen. Ethisch relevant ist außerdem die Vermeidung von Stigmatisierung: Individuelle Risikoprofile könnten trotz XAI-Transparenz zu diskriminierenden Entscheidungen führen, wenn Führungskräfte nicht entsprechend geschult sind. Diese Herausforderungen machen standardisierte Frameworks für den ethischen Einsatz von KI im BGM erforderlich, wie sie etwa in der EU-KI-Verordnung skizziert werden.

Ergänzend ist zu berücksichtigen, dass Maßnahmen im Rahmen des betrieblichen Gesundheitsmanagements grundsätzlich keinen verpflichtenden Charakter haben, sondern als freiwillige Angebote für Beschäftigte zu verstehen sind. Die Implementierung und Nutzung entsprechender Maßnahmen liegt somit im Ermessen der Unternehmen und erfolgt stets unter Berücksichtigung organisatorischer Rahmenbedingungen sowie der individuellen Inanspruchnahme durch die Beschäftigten. Vor diesem Hintergrund können die dargestellten Ergebnisse insbesondere Hinweise für eine freiwillige, evidenzbasierte Ausgestaltung entsprechender Angebote liefern, ohne daraus eine verpflichtende Umsetzung abzuleiten.

Praktische Implikationen

Die Ergebnisse liefern nicht nur Evidenz für zentrale Einflussgrößen auf die Arbeitsfähigkeit, sondern zeigen auch, wie XAI in systematische, adaptive Steuerungsinstrumente des BGM überführt werden kann. Dashboards, die prädiktive Modellierung mit Echtzeit-SHAP-Analysen integrieren, ermöglichen es, nicht nur statische Kennzahlen, sondern auch dynamische Frühindikatoren und Treiberprofile zu visualisieren und Veränderungen im Arbeits- und Gesundheitszustand der Beschäftigten kontinuierlich nachzuverfolgen. Durch die transparente Aufbereitung der einzelnen Beiträge der Faktoren wird eine Brücke zwischen datengetriebener Vorhersage und interpretierbarer Entscheidungsunterstützung geschaffen, wie sie für die Implementierung von XAI in Gesundheits- und Managementprozesse in der Literatur als zentraler Erfolgsfaktor beschrieben wird (Johannssen u. Chukhrova 2025).

Dieser Ansatz entspricht dem Konzept der Precision Prevention im Arbeitskontext (Blaschke et al. 2024): Statt universeller Maßnahmen werden Interventionen anhand Treiberstrukturen und individualisierter Risikoprofile priorisiert, um effektiver auf belastungsspezifische Bedürfnisse einzugehen. Dies bedeutet, dass gesundheitsbezogene Kompetenzen und Lebensqualitätsindikatoren nicht nur retrospektiv analysiert, sondern auch proaktiv zur Steuerung der Gesundheitsförderung genutzt werden können, unter Berücksichtigung der jeweils geltenden Datenschutzerfordernisse. Präventionsmaßnahmen können gezielt umgesetzt werden, bevor aus Risikokonstellationen reduzierte Arbeits-

fähigkeit oder manifeste Fehlzeiten entstehen, was dem Paradigma vorbeugender, datenbasierter Gesundheitsstrategien entspricht.

Darüber hinaus kann die Nutzung von XAI nicht nur auf individueller Ebene erfolgen, sondern auch in aggregierter Form auf Abteilungs- oder Team-Ebene wertvolle Einblicke liefern. Aggregierte SHAP-Profile ermöglichen es, gruppenspezifische Risiko- und Schutzfaktoren zu identifizieren und organisationsweite Interventionsbedarfe herauszuarbeiten. Dieser Aspekt geht über die individualisierte Risikobetrachtung hinaus und unterstützt strategische Entscheidungsprozesse. Ebenso können Benchmarking-Funktionen sektorübergreifend integriert werden, wodurch beispielsweise teamspezifische Risikomuster im Vergleich zu Referenzwerten sichtbar werden und die adaptive Maßnahmenplanung erleichtert. Die exemplarisch gezeigte XAI-Analyse beschränkte sich auf ausgewählte Einflussfaktoren und auf ein modellbasiertes Framework. Zukünftige Entwicklungen können weitere Prädiktoren (zum Beispiel arbeitsorganisatorische Merkmale, psychosoziale Belastungen) integrieren oder moderne Analyseansätze wie Risikovorhersagemodellierungen, kausalitätsorientierte Verfahren und kontrafaktische Simulationen einsetzen. Dadurch werden nicht nur Assoziationen, sondern auch mögliche Ursache-Wirkungs-Beziehungen und Vorhersagen adressiert. Insgesamt sollten BGM-Kennzahlensysteme offen und innovativ mit XAI-Methoden angereichert werden, um die Transformation von reaktiven zu präventiven Steuerungsinstrumenten zu beschleunigen und gleichzeitig Precision Prevention-Ansätze in der organisatorischen Praxis zu verankern.

Schlussfolgerungen und Ausblick

Zusammenfassend belegen die Befunde die zentrale Rolle von Lebensqualität und Gesundheitskompetenz als Prädiktoren der Arbeitsfähigkeit und plädieren für deren Integration in ganzheitliche BGM-Kennzahlensysteme. XAI-Methoden wie SHAP bilden hierbei eine Brücke zwischen datengetriebener Präzision und praktischer Nachvollziehbarkeit, was insbesondere in ressourcenknappen Zeiten einen strategischen Vorteil darstellt. Der Ausblick richtet sich auf die Entwicklung personalisierter Gesundheitsassistenzsysteme, die über Chatbots und Wearables Daten in Echtzeit speisen, um schrittweise einen digitalen Gesundheitszwilling (Digital Health Twin) des Beschäftigten zu erstellen (Kobayashi u. Alam 2024). Das vorliegende SHAP-basierte Vorhersagemodell stellt einen wichtigen Schritt in Richtung eines digitalen Gesundheitszwillings für die Arbeitsfähigkeit dar. Aktuelle Analysen auf Basis von Querschnittsdaten liefern lediglich Momentaufnahmen. Längsschnittmessungen, automatisierte Daten und Interventionsfeedback könnten hingegen dynamische, kontinuierlich lernende Einblicke in die individuelle Entwicklung der Arbeitsfähigkeit ermöglichen. Damit könnte das BGM zu einer individualisierten, datengestützten und vorausschauenden Disziplin werden, die die Arbeitsfähigkeit nachhaltig fördert und zugleich die Wettbewerbsfähigkeit der Unternehmen stärkt.

Interessenkonflikt: Die Autoren geben an, dass keine Interessenkonflikte vorliegen.

Finanzierung/Förderung: Diese Forschung erhielt keine spezifische Förderung.

Ethikerklärung: Die vorliegende Untersuchung basiert auf der Einhaltung der Deklaration von Helsinki. Vor Beginn der Studie wurde ein Ethikantrag bei der Ethikkommission der Technischen Universität München (2025-113-NM-BA) eingereicht und am 09.10.2025 positiv beschieden.

Datenverfügbarkeit: Die Daten können auf begründete Anfrage bei der korrespondierenden Autorin/dem korrespondierenden Autor angefordert werden.

Autorenschaft und Beiträge: J.F. und S.B. konzipierten die Studie und entwickelten das Studiendesign. J.F. und S.B. waren für die Datenerhebung verantwortlich. J.F. führte die Datenanalyse durch. J.F. und S.B. interpretierten die Ergebnisse und verfassten das Manuskript. J.F., F.M. und S.B. überarbeiteten das Manuskript kritisch hinsichtlich wichtiger intellektueller Inhalte. Alle Autorinnen und Autoren überprüften und genehmigten die finale Version des Manuskripts und stimmten der Veröffentlichung zu.

Software & KI: Für die statistischen Analysen wurde R Version 4.5.0 verwendet. KI-Tools wurden ausschließlich zur sprachlichen Glättung eingesetzt. Alle Inhalte wurden von den Autorinnen und Autoren überprüft.

Literatur

- Alkhanbouli R, Matar Abdulla Almadhaani H, Alhosani F, Simsekler MCE: The role of explainable artificial intelligence in disease prediction: a systematic literature review and future research directions. *BMC Med Inform Decis Mak* 2025; 25: 110. doi:10.1186/s12911-025-02944-6 (Open Access).
- Atanasova S, Kamin T: From dimensions, levels and domains to context-specific conceptualizations of health literacy. *Slovenian J Public Health* 2022; 61: 133–136. doi:10.2478/sjph-2022-0018 (Open Access).
- Baumgardt J, Klawisch H: Wie geht es den Beschäftigten in Deutschland – Ergebnisse aus Befragungen zwischen 2020 und 2025. In: Badura B, Ducki A, Meyer M, Baumgardt J, Schröder (Hrsg.): *Fehlzeiten-Report 2025* [Internet]. Berlin, Heidelberg: Springer Berlin Heidelberg; 2025 [cited 2026 Feb 6]. S. 319–44. (Fehlzeiten-Report). Available from: https://link.springer.com/10.1007/978-3-662-71885-8_23 doi:10.1007/978-3-662-71885-8_23
- Bergman E, Löytyniemi E, Myllyntausta S, Rautava P, Korhonen PE: Factors associated with quality of life and work ability among Finnish municipal employees: a cross-sectional study. *BMJ Open* 2020; 10: e035544. doi:10.1136/bmjopen-2019-035544 (Open Access).
- Bhatt AB: Health literacy: The hidden KPI for innovation in healthcare. *Forbes* [Internet]. 2025. Available from: <https://www.forbes.com/councils/forbestechcouncil/2025/11/25/health-literacy-the-hidden-kpi-for-innovation-in-healthcare/>
- Blaschke S, Friedrich J, Mess F: „Precision Health“ im Betrieblichen Gesundheitsmanagement: Ein Literaturüberblick und Handlungsempfehlungen. *ASU Arbeitsmed Sozialmed Umweltmed* 2024; 59: 32–37. doi:10.17147/asu-1-328879 (Open Access).
- Dindarian K: Demografie, Bildung und Beschäftigungsdynamik. In: *Unvorhergesehenes als Chance sehen – Black Swan* [Internet]. Cham: Springer International Publishing; 2024 [cited 2026 Feb 6]. S. 177–212. Available from: https://link.springer.com/10.1007/978-3-031-57176-3_13 doi:10.1007/978-3-031-57176-3_13
- Drixler K, Morfeld M, Glaesmer H, Brähler E, Wirtz MA: Validierung der Messung gesundheitsbezogener Lebensqualität mittels des Short-Form-Health-Survey-12 (SF-12 Version 2.0) in einer deutschen Normstichprobe. *Z Psychosom Med Psychother* 2020; 66: 272–286. doi:10.13109/zptm.2020.66.3.272 (Open Access).
- Ebener M, Hasselhorn H: Validation of short measures of work ability for research and employee surveys. *IJERPH* 2019; 16: 3386. doi:10.3390/ijerph16183386 (Open Access).
- Farantos GI, Dounias G: Key performance indicators in occupational health and safety of hospitals: A scoping review with meta-analysis. *Giornale Italiano di Psicologia e Medicina del Lavoro* 2024; 4: 12. doi:10.69088/2024/KYPR3.
- Feldt T, Hyvönen K, Mäkitangas A, Kinnunen U, Kokko K: Development trajectories of Finnish managers' work ability over a 10-year follow-up period. *Scand J Work Environ Health* 2009; 35: 37–47. doi:10.5271/sjweh.1301.
- Friedrich J, Münch AK, Thiel A, Voelter-Mahlknecht S, Sudeck G: OHLS: Ein Fragebogen zur Messung arbeitsbezogener Gesundheitskompetenz. *Public Health Forum* 2022; 30: 83–85. doi:10.1515/pubhef-2022-0005.

- Friedrich J, Münch AK, Thiel A, Voelter-Mahlknecht S, Sudeck G: Occupational Health Literacy Scale (OHLs): development and validation of a domain-specific measuring instrument. *Health Promotion Int.* 2023; 38: daac182. doi:10.1093/heapro/daac182.
- Friedrich J, Rupp M, Feng YS, Sudeck G: Occupational health literacy and work ability: a moderation analysis including interpersonal and organizational factors in healthy organizations. *Front Public Health* 2024; 12: 1243138. doi:10.3389/fpubh.2024.1243138 (Open Access).
- Gernert M, Stassen G, Schaller A: Association between health literacy and work ability in employees with health-related risk factors: a structural model. *Front Public Health* 2022; 10: 804390. doi:10.3389/fpubh.2022.804390 (Open Access).
- Güttler C, Kohls N: Gesundheitskompetenz von Mitarbeitenden: Eine fragebogen-basierte Studie in einem Unternehmen der Metallindustrie. *Präv Gesundheitsf* 2022; 17: 349–356. doi:10.1007/s11553-021-00883-4 (Open Access).
- Hasselhorn HM, Freude G: Der Work Ability Index: ein Leitfaden. Bremerhaven: Wirtschaftsverlag NW, Verlag für neue Wissenschaften, 2007. S. 54 (Schriftenreihe der Bundesanstalt für Arbeitsschutz und Arbeitsmedizin Sonderschrift; no. 87).
- Hulsen T: Explainable Artificial Intelligence (XAI): Concepts and Challenges in Healthcare. *AI* 2023; 4: 652–666. doi:10.3390/ai4030034 (Open Access).
- Johannssen A, Chukhrova N: The crucial role of explainable artificial intelligence (XAI) in improving health care management. *Health Care Manag Sci* 2025; 28: 565–570. doi:10.1007/s10729-025-09720-y (Open Access).
- Jungkunz C, Rogowski W, Larjow E: Betriebliches Gesundheitsmanagement II. In: Rogowski W (Hrsg.): *Management im Gesundheitswesen* [Internet]. Wiesbaden: Springer Fachmedien, 2023 [cited 2026 Feb 6]. S. 233–243. Available from: https://link.springer.com/10.1007/978-3-658-39639-8_29.
- Kobayashi K, Alam SB: Explainable, interpretable, and trustworthy AI for an intelligent digital twin: A case study on remaining useful life. *Eng Appl Artif Intell* 2024; 129: 107620. doi:10.1016/j.engappai.2023.107620.
- Kunz C, Millhoff C: A longitudinal perspective on the interplay of job demands and destructive leadership on employees' work ability in Germany. *Int Arch Occup Environ Health* 2023; 96: 735–745. doi:10.1007/s00420-023-01962-z (Open Access).
- Lange M, Löwe A, Kayser I, Schaller A: Approaches for the use of AI in workplace health promotion and prevention: systematic scoping review. *JMIR AI* 2024; 3: e53506. doi:10.2196/53506 (Open Access).
- Li X, Deng S, Li L, Jiang Y: Outlier detection based on robust mahalanobis distance and its application. *OJS* 2019; 09: 15–26. doi:10.4236/ojs.2019.91002 (Open Access).
- Lohela Karlsson M, Busch H, Aboagye E, Jensen I: Validation of a measure of health-related production loss: construct validity and responsiveness – a cohort study. *BMC Public Health* 2015; 15: 1148. doi:10.1186/s12889-015-2449-z (Open Access).
- Magnavita N, Meraglia I, Viti G, Borghese L: The Work Ability Index (WAI) in the Healthcare Sector: A cross-sectional/retrospective assessment of the questionnaire. *IJERPH* 2024; 21: 349. doi:10.3390/ijerph21030349 (Open Access).
- Mess F, Blaschke S, Gebhard D, Friedrich J: Precision prevention in occupational health: a conceptual analysis and development of a unified understanding and an integrative framework. *Front Public Health* 2024; 12: 1444521. doi:10.3389/fpubh.2024.1444521 (Open Access).
- Mess F, Blaschke S, Schick TS, Friedrich J: Precision prevention in worksite health – A scoping review on research trends and gaps. *PLoS ONE* 2024; 19: e0304951. doi:10.1371/journal.pone.0304951 (Open Access).
- Mokarami H, Cousins R, Kalteh HO: Comparison of the work ability index and the work ability score for predicting health-related quality of life. *Int Arch Occup Environ Health* 2022; 95: 213–221. doi:10.1007/s00420-021-01740-9.
- Mokheleli T, Bokaba T, Mbunge E: Explainable Artificial Intelligence for Workplace Mental Health Prediction. *Informatics* 2025; 12: 130. doi:10.3390/informatics12040130 (Open Access).
- Moll T: Potenziale digitaler und KI-basierter Tools zur Gesundheitsförderung in Unternehmen – Eine systemtheoretische Beobachtung von Implementierungs- und Verankerungsprozessen. In: Pfannstiel MA (Hrsg.): *Künstliche Intelligenz im Gesundheitswesen* [Internet]. Wiesbaden: Springer Fachmedien, 2022 [cited 2026 Feb 6]. S. 349–373. Available from: https://link.springer.com/10.1007/978-3-658-33597-7_15.
- Mollaei N, Fujao C, Silva L, Rodrigues J, Cepeda C, Gamboa H: Human-centered explainable artificial intelligence: automotive occupational health protection profiles in prevention musculoskeletal symptoms. *IJERPH* 2022; 19: 9552. doi:10.3390/ijerph19159552 (Open Access).
- Müters S, Michalski N, Hoebel J: Aktualisierung der Berechnungsgrundlagen für den Index des sozioökonomischen Status in der Studie Gesundheit in Deutschland aktuell (GEDA) 2019/2020-EHIS [Update of the calculation basis for the socio-economic status index in the Health in Germany 2019/2020-EHIS study] [Internet]. Robert Koch-Institut, 2023 [cited 2025 May 5]. Available from: <https://edoc.rki.de/handle/176904/11168> doi:10.25646/11444.
- Nutbeam D, Lloyd JE: Understanding and responding to health literacy as a social determinant of health. *Annu Rev Public Health* 2021; 42: 159–173. doi:10.1146/annurev-publhealth-090419-102529 (Open Access).
- Park HS, Kim KI, Chung HY et al.: A worker-centered personal health record app for workplace health promotion using national health care data sets: design and development study. *JMIR Med Inform* 2021; 9: e29184. doi:10.2196/29184 (Open Access).
- Pelikan JM, Ganahl K, Van Den Broucke S, Sørensen K: Measuring health literacy in Europe: Introducing the European Health Literacy Survey Questionnaire (HLS-EU-Q). In: Okan O, Bauer U, Levin-Zamir D, Pinheiro P, Sørensen K (Hrsg.): *International Handbook of Health Literacy: Research, practice and policy across the lifespan*. Bristol: Policy Press, 2019, S. 115–138.
- Rohrbacher M, Hasselhorn HM: Social inequalities in early exit from employment in Germany: a causal mediation analysis on the role of work, health, and work ability. *Scand J Work Environ Health* 2022; 48: 569–578. doi:10.5271/sjweh.4043 (Open Access).
- Röthlin F, Pelikan JM, Ganahl K: Die Gesundheitskompetenz der 15-jährigen Jugendlichen in Österreich. Abschlussbericht der österreichischen Gesundheitskompetenz Jugendstudie im Auftrag des Hauptverbands der österreichischen Sozialversicherungsträger (HVSFV). Vienna: Ludwig Boltzmann Institut Health Promotion Research (LBIHPR); 2013.
- Sakai K, Nakazawa S, Furuya Y, Fukui K, Sano K, Tatemichi M: Key performance indicators in workplace health promotion: a cross-sectional text-mining study of feedback sheets from government-led health and productivity management initiatives in Japan. *J Occup Environ Med* 2026; 68: e61–68. doi:10.1097/JOM.0000000000003542 (Open Access).
- Salih AM, Raisi-Estabragh Z, Galazzo IB et al.: A perspective on explainable artificial intelligence methods: SHAP and LIME. *Adv Intel Sys* 2025; 7: 2400304. doi:10.1002/aisy.202400304 (Open Access).
- Shah IA, Mishra S: Artificial intelligence in advancing occupational health and safety: an encapsulation of developments. *J Occup Health* 2024; 66: uiad017. doi:10.1093/joccuh/uiad017 (Open Access).
- Siegel A, Hoge AC, Ehmann AT, Martus P, Rieger MA: Attitudes of company executives toward a comprehensive workplace health management – results of an exploratory cross-sectional study in Germany. *IJERPH* 2021; 18: 11475. doi:10.3390/ijerph182111475 (Open Access).
- Sørensen K, Van den Broucke S, Fullam J et al.: Health literacy and public health: A systematic review and integration of definitions and models. *BMC Public Health* 2012; 12. doi:10.1186/1471-2458-12-80 (Open Access).
- Stapelfeldt CM, Jensen C, Andersen NT, Fleten N, Nielsen CV: Validation of sick leave measures: self-reported sick leave and sickness benefit data from a Danish national register compared to multiple workplace-registered sick leave spells in a Danish municipality. *BMC Public Health* 2012; 12: 661. doi:10.1186/1471-2458-12-661 (Open Access).
- Statistisches Bundesamt: Erwerbstätige und Arbeitnehmer nach Wirtschaftsbereichen [Internet]. 2026. Available from: <https://www.destatis.de/DE/Themen/Arbeit/Arbeitsmarkt/Erwerbstätigkeit/Tabellen/arbeitnehmer-wirtschaftsbereiche.html>
- Treier M: Legitimation des Betrieblichen Gesundheitsmanagements. In: *Betriebliches Gesundheitsmanagement* [Internet]. Berlin, Heidelberg: Springer, 2023 [cited 2026 Feb 6]. S. 255–293. Available from: https://link.springer.com/10.1007/978-3-662-67152-8_6
- Uhle T, Treier M: Betriebliches Gesundheitsmanagement: Gesundheitsförderung in der Arbeitswelt – Mitarbeiter Einbinden, Prozesse Gestalten, Erfolge Messen. 4th ed. Wiesbaden: Springer Vieweg, 2019, S. 1.
- Van Den Berg TIJ, Elders LAM, De Zwart BCH, Burdorf A: The effects of work-related and individual factors on the Work Ability Index: a systematic review. *Occup Environ Med* 2009; 66: 211–220. doi:10.1136/oem.2008.039883.
- Virgillito D, Ledda C: Personalized AI for workplace health promotion: performance management and healthcare worker engagement through digital analytics. *Front Public Health* 2026; 13: 1718474. doi:10.3389/fpubh.2025.1718474 (Open Access).
- Voss M, Stark S, Alfredsson L, Vingård E, Josephson M: Comparisons of self-reported and register data on sickness absence among public employees in Sweden. *Occup Environ Med* 2008; 65: 61–67. doi:10.1136/oem.2006.031427.
- Wellmann H: Monitoring im betrieblichen Gesundheitsmanagement (Study Nr. 389) [Internet]. Hans-Böckler-Stiftung, 2018. Available from: https://www.boeckler.de/fpdf/HBS-006896/p_study_hbs_mbf_bvd_389.pdf
- Whitaker RG, Sperber N, Baumgartner M et al.: Coincidence analysis: a new method for causal inference in implementation science. *Implementation Sci* 2020; 15: 108. doi:10.1186/s13012-020-01070-3 (Open Access).
- Wirtz MA, Morfeld M, Glaesmer H, Brähler E: Normierung des SF-12 Version 2.0 zur Messung der gesundheitsbezogenen Lebensqualität in einer deutschen bevölkerungsrepräsentativen Stichprobe. *Diagnostica* 2018; 64: 215–226. doi:10.1026/0012-1924/a000205.
- Yazdipour AB, Mehdizadeh P, Arabfard M, Yaghoubi M, Farahani MM, Amiri-Ara M: Development and implementation of explainable AI-based machine learning models for predicting hospital stay and treatment costs in cardiovascular patients. *Sci Rep* 2025; 16: 3154. doi:10.1038/s41598-025-33005-7 (Open Access).
- Zwetsloot G, Leka S, Kines P, Jain A: Vision zero: Developing proactive leading indicators for safety, health and wellbeing at work. *Safety Sci* 2020; 130: 104890. doi:10.1016/j.ssci.2020.104890 (Open Access).

Kontakt

Dr. Julian Friedrich

Technische Universität München
Am Olympiacampus 11, 80809 München
julian.friedrich@tum.de