FINANZIERUNG
LEASING
FACTORING
FLF

6

NOVEMBER 2026 · 73. JAHRGANG



DIGITALER SONDERDRUCK

DIGITALISIERUNG

Wenn das Asset spricht …

Risikomanagement 2.0: von Erfahrungswerten zur Echtzeit-Entscheidung

Dr. Lars Rüsberg
Innovating Innovators, Interest Group Finance & Insurance des Digital Industries World e.V.

Wenn das Asset spricht …

Risikomanagement 2.0: von Erfahrungswerten zur Echtzeit-Entscheidung

Maschinen liefern längst mehr als Leistung: Sie liefern Daten. Wer sie richtig liest, erkennt Risiken früher, steuert Investitionen besser und schafft Raum für neue Geschäftsmodelle.
Zum fünften Mal berichtet Dr. Lars Rüsberg aus der Arbeit des Digital Industries World e. V. Im Fokus der Interest Group Finance & Insurance steht ein neues Verständnis von Risiko: Industrie, Finanzierung und Versicherung müssen technische Daten in belastbare Wert- und Risikoindikatoren übersetzen. Künstliche Intelligenz kann dabei beschleunigen – Entscheiden bleibt aber Aufgabe kompetenter Menschen. Und diese sollten sich ihre Validierungskompetenz bewahren. (Red.)

Investitionen verbinden immer stärker Operational Technology (OT) und IT. Sensoren, Telemetrie- und Geodaten zeigen, wie Anlagen genutzt werden, in welchem Zustand sie sind und wann Ausfälle drohen. Digitale Zwillinge simulieren Verhalten, erkennen Fehlermuster und Wertentwicklungen. So entstehen neue Angebote: Im Rahmen der digitalen Transformation werden vermehrt nicht nur Produkte, sondern in Asset as a Service-Modellen die passenden Ersatzteile, Verbrauchsgüter oder Dienstleistungen angeboten – für den laufenden Betrieb über Predictive Maintenance und notwendige Wartungsleistungen (noch vor dem Ausfall einer Maschine) bis hin zur Finanzierung ("Embedded Finance"). Kurz: Alles ist vernetzt – aber noch nicht ausreichend gesteuert.

Asset-Kompetenz gewinnt an Bedeutung

Finanzierungsentscheidungen folgen bisher meist einem bekannten Muster: Erst zählt die Bonität, dann das Asset. Sicherheiten, Bürgschaften oder verwertbare Objekte federn Risiken ab. Nur selten trägt sich eine Finanzierung allein aus dem Cashflow des Assets. Bei Versicherungen steht das Objekt zwar stärker im Mittelpunkt – doch auch hier gilt:

Wer Assets besser versteht, kann Risiken präziser kalkulieren, bessere Konditionen anbieten und mehr finanzieren oder absichern. Dafür reicht der Blick auf historische Daten nicht mehr. Risikomanagement wird vom einmaligen Ereignis zum laufenden Prozess.



DR. LARS RÜSBERG

ist Gründer von Innovating Innovators, München, und Leiter der Interest Group Finance & Insurance des Digital Industries World e. V.

Historische Daten bleiben wichtig. Zunehmend werden sie jedoch ergänzt durch den kontinuierlichen Datenstrom über den Lebenszyklus des Assets – mindestens während der Finanzierungs- oder Versicherungsdauer.

Geodaten ermöglichen den Nachweis, dass das Objekt am vereinbarten Ort oder auf der vereinbarten Route ist, Nutzungs- und Zustandsdaten zeigen Auslastung, Verschleißdaten können (über Fehlermeldungen) Maßnahmen auslösen, die zum Beispiel Stillstandszeiten oder einen Totalausfall vermeiden. Zugleich wird sichtbar, ob ein Business Plan trägt. Ein Asset, das planbar arbeitet und engmaschig überwacht werden kann, lässt sich (besser) finanzieren und versichern.

IoT-based Finance & Insurance

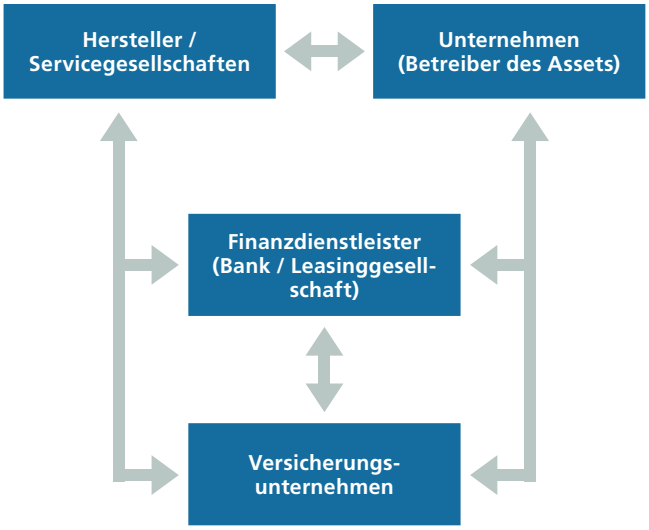
Die Grundlage sind Daten – und der Zugang zu ihnen wird neu geregelt. Der EU Data Act und verwandte Regelwerke schaffen Nutzungs- und Zugangsrechte. Hersteller müssen Daten zunehmend über ein „Access by Design" bereitstellen. Das ist ein Anfang – löst aber das Problem nicht.

Entscheidend sind drei Fragen:

- wer braucht welche Daten für seine Vertriebs-, Wartungs-, Bewertungs-, Finanzierungs-, und/oder Versicherungsentscheidungen,
- wer verfügt über sie und gibt sie unter welchen Bedingungen weiter und
- wer transformiert sie von technischen Zustands- und Betriebsdaten in relevante Risikoindikatoren – mit Kontextualisierung und Übersetzung in die Sprache der Risikomanager.

Die relevanten Daten liegen verteilt: bei Herstellern und/oder gegebenenfalls Servicegesellschaften, Betreibern, Finanzierern und Versicherern.

Abbildung 1: Der neue Datenkreislauf



Quelle: Eigene Darstellung

Keine der Parteien verfügt über "alle" relevanten Daten für die Echtzeit-Analytic und die fachliche Bewertung von Risiken und/oder Wertverläufen.

Daten zu teilen, bleibt sensibel – regulatorisch, technisch und wirtschaftlich. Aus Betreibersicht wird schnell mit dem Datenschutz argumentiert: Meine Daten verraten zu

»Wer beste Entscheidungen und Konditionen haben will, muss auch beste Daten geben.«

viel über mich und meine Produktion (Transparenz durch zusätzliche Einblicke in die Auslastung von Maschinen) und/oder Fertigungs-Know how (Gefährdung von

Der BEV-Effekt: Batterieelektrische Fahrzeuge zeigen, warum historische Durchschnittswerte nicht mehr genügen. Ihr wirtschaftlicher Wert hängt stark vom Zustand der Batterie ab, ihrer Nutzung und Ladung – und damit von aktuellen Daten. Finance und Insurance müssen vom Blick in den Rückspiegel zum vorausschauenden Steuern kommen. KI kann helfen, wenn Datenqualität, Modellkontrolle und menschliche Validierung stimmen.

Intellectual Property). Hersteller fühlen sich mehr dem Betreiber verpflichtet als dem Eigentümer, zum Beispiel einer Leasing-Gesellschaft. Finanzdienstleister und Versicherer unterliegen strengen Vorgaben; gleichzeitig prägen Datenschutz, ESG, IT-Security und Resilienzanforderungen den Rahmen.

Aber: Daten entscheiden künftig mit darüber, ob Verträge zustande kommen, wie Risiken bepreist werden und welche Konditionen möglich sind.

Anforderungen an die Daten-Architektur

Damit Maschinendaten in Kreditentscheidungen, Leasing-Restwerten oder Versicherungstarifen genutzt werden können, müssen sie hohen Standards genügen: vollständig, nachvollziehbar, manipulationssicher und regulatorisch belastbar.

Dafür braucht es eine Architektur, die im Alltag funktioniert: robust genug für Aufsicht und Audit, flexibel genug für neue Use Cases und offen genug für Partner im Ökosystem.

- Daten müssen vom Sensor bis zum Risikoreporting unverändert, lückenlos nachvollziehbar und geschützt verarbeitet werden.
- Die Architektur sollte DORA, DSGVO und auch BCBS 239 berücksichtigen, Drittparteien sauber steuern und Datensouveränität absichern.

Die unten stehende Grafik visualisiert die Architektur, über die Daten schrittweise von der physischen Maschine bis in die Kernsysteme des Finanzdienstleisters überführt werden.

Die wichtigsten Aspekte der vier Kernschichten der Architektur im Detail:

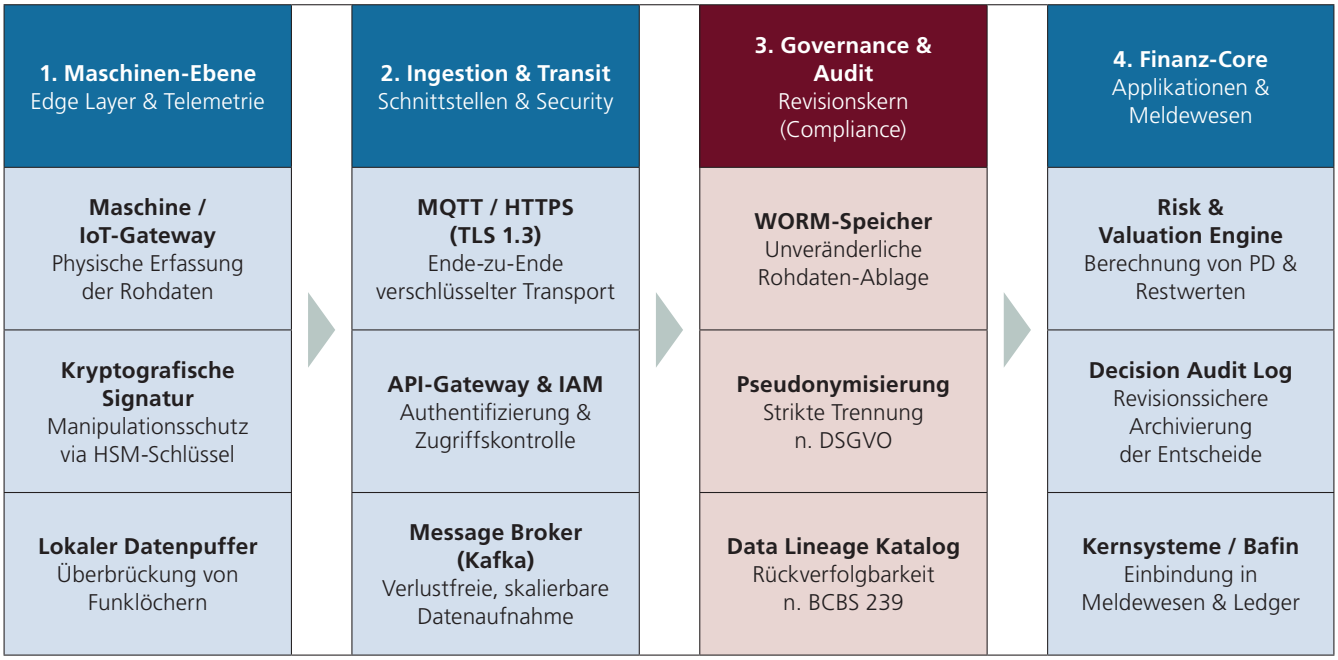
Maschinenschicht (Edge Layer):

- **IoT-Gateway:** Erfasst werden Daten wie Hersteller der Maschine, Firmware-Version, Sensor-Typ, Kalibrierungsdatum, Wartungsstatus oder Zertifikatsstatus.
- **Kryptografische Signierung:** Jedes Datenpaket wird direkt auf der Maschine oder dem IoT-Gateway mit einem eindeutigen, im Hardware-Sicherheitsmodul (HSM) hinterlegten Schlüssel des Geräts kryptografisch signiert. Dies verhindert „Spoofing" (Einspeisen falscher Daten).
- **Lokaler Puffer:** Bei Funkabbrüchen werden Daten lokal verschlüsselt zwischengespeichert, um die von der Aufsicht geforderte Vollständigkeit zu garantieren.

Ingestion & Transit (Übertragung):

- **Abgesicherter Transport:** Die Übertragung erfolgt zwingend über verschlüsselte Protokolle (zum Beispiel MQTT via TLS 1.3 oder HTTPS).
- **API-Gateway & IAM:** Ein zentrales Identity & Access Management (IAM via OAuth2) stellt sicher, dass nur authentifizierte Maschinen und Systeme Daten einspeisen oder abrufen dürfen (Schutz der kritischen Infrastruktur nach DORA).

Abbildung 2: End-to-End Datenfluss-Compliance gemäß DORA, BCBS 239 und DSGVO



Quelle: Eigene Darstellung

Data Governance & Audit Trail – das revisionssichere Herzstück:

- **Message Broker & Immutable Log:** Ein System wie Apache Kafka nimmt die Daten auf. Die Rohdaten werden in einem unveränderlichen Speicher (WORM – Write Once Read Many) abgelegt. Einmal geschriebene Daten können von niemandem – auch nicht vom Administrator – nachträglich verändert oder gelöscht werden. Hier setzt auch ein eigenständiger Data Quality Layer auf mit diversen Checks, zum Beispiel auf Completeness, Accurancy, Consistancy, Validity und Timelines.

- **Pseudonymisierungs-Engine:** Um der DSGVO zu entsprechen, werden personenbezogene Merkmale (zum Beispiel Fahrer-ID, Standort) sofort vom technischen Datensatz getrennt und durch Pseudonyme ersetzt. Die Zuordnungstabelle liegt in einer hochgesicherten separaten Zone.

- **Hash-Verankerung/Blockchain:** Zur mathematischen Absicherung der Integrität werden Datenblöcke gehasht. Diese Hashes können optional in einer privaten Blockchain oder einem manipulationssicheren Ledger verankert werden. Ein Auditor kann die Hashes jederzeit abgleichen, um die Unverfälschbarkeit zu prüfen.

- **Data Lineage Katalog:** Jede Transformation (zum Beispiel Aggregation von Minuten- zu Tageswerten) wird in einem Metadatenkatalog dokumentiert. Dies erfüllt die BCBS 239-Forderung: Der Weg jeder Kennzahl muss bis zur Quelle nachvollziehbar sein.

Finanz-Core & Applikationen (Konsumtion):

- **Risikomodellierung (Risk Engine):** Validierte Algorithmen berechnen aus den bereinigten Daten Kennzahlen wie die Ausfallwahrscheinlichkeit (PD/LGD) im Kreditbereich oder Verschleißwerte zum Beispiel für das Leasing-Restwertrisiko.

- **Audit Log Repository:** Jede Entscheidung (zum Beispiel eine automatische Kredit- oder Tarifanpassung durch die Risk Engine) wird zusammen mit der zugrunde liegenden Datenbasis revisionssicher archiviert. So kann bei einer Bafin-Prüfung exakt nachgewiesen werden, warum ein Algorithmus zu einem bestimmten Zeitpunkt so entschieden hat (EU AI Act Compliance).

Handlungsbedarf: Nur gemeinsam sind wir stark

Damit stehen gleich mehrere große Aufgaben an: die Bestimmung

- **fachlich** der „richtigen" Parameter, die ein neues Risikomanagement etablieren helfen; hier gilt es, die KI nicht zu überschätzen, die eigenen Fähigkeiten im Sinne einer Validierungskompetenz aufrechtzuerhalten, die Organisation zu befähigen und Führung in durch KI veränderten Zeiten neu zu leben;

- **systemtechnisch** einer Vertrauensplattform, in die die notwendigen Daten für den allgemeinen (sicheren) Zugriff eingespeist werden können,

› **organisatorisch-technisch** geeigneter Governance- und IT-Strukturen, die zuverlässig, vertrauenswürdig und regulatorisch compliant die notwendige Datenbasis schaffen, auf denen jeder einzelne seine Risikomodelle adjustieren kann.

Die Interest Group Finance & Insurance hat gezeigt, wie solche Übersetzungsarbeit gelingen kann. Beim Pay-per-Use-Geschäft wurden unterschiedliche Marktansätze auf vier Modelle verdichtet – als gemeinsame Sprache für Kunden, Hersteller, Finanzierer und Versicherer.

Für Asset-Daten braucht es nun denselben Schulterschluss. Verbände wie Digital Industries World oder der Bundesverband Deutscher Leasing-Unternehmen können Thought Leadership übernehmen und die relevanten Akteure an einen Tisch bringen. Entscheidend ist ein klarer Call-to-Action: gemeinsame Datenlogik, gemeinsame Governance, gemeinsame Umsetzung.

Arbeitsergebnisse und Impulse

Die folgenden Beiträge bündeln Ergebnisse und Impulse der Interest Group Finance & Insurance 2026 – aus unterschiedlichen Perspektiven:

› der Leasing-Industrie (Dr. Claudia Conen, Bundesverband Deutscher Leasing-Unternehmen),

› eines Versicherungsunternehmens (Christoph Bauer, HDI Global/PROTH!NX) und

› des Innovationsmanagements (Boris Scharinger, Siemens Digital Industries) und

› einer notwendigerweise zu verändernden Unternehmensführung mit erweiterten Freiräumen und Verantwortlichkeiten für die Mitarbeitenden (Prof. Benjamin Jäcklin, KIENBAUM/Digital Business University).

Der Mehrwert liegt im Praxisblick: keine generische Transformationsrhetorik, sondern Erfahrungen von Vorreitern, die in einer vertrauensvollen Community konkrete Lösungen entwickeln – branchenübergreifend, pragmatisch und auf den Punkt.

DIW Financial Summit 2026: „Predict. Prevent. Profit."
Der alle zwei Jahre stattfindende DIW Financial Summit – 2026 ausgerichtet von **HDI Global SE und Siemens Financial Services** – brachte Praxisimpulse, offene Diskussionen und konkrete Learnings zusammen. Im Mittelpunkt standen nicht nur Success Stories, sondern auch Stolperfallen, Trends und die Frage, wie Industrie, Finance und Versicherung gemeinsam Mehrwerte aus Daten schaffen. Durch den laufenden Austausch entstehen vertrauensvolle Netzwerke und wegweisende Thought Leadership – mit Lösungen für die Praxis.

Fußnoten:
1) Die Systeme, die Entscheidungen prozessieren, sind meist „historisch" und gar nicht darauf ausgelegt, die erforderlichen Daten zu sammeln oder gar für Entscheidungen aufbereitet zur Verfügung zu stellen.
2) Dennoch ist das Pay-per-Use-Geschäft bislang nicht „ans Fliegen gekommen" – teils aufgrund des fehlenden Bedarfs (Abdeckung kurzzeitiger Spitzen in der Produktion) oder guter Alternativen (Mietpark-Modelle), teils aufgrund unterschiedlicher Erwartungen, wer zu welchem Preis insbesondere das Auslastungsrisiken zu übernehmen oder abzusichern hat.

Die Rolle von (Asset-)Daten im Leasing

Kein anderer Finanzierer sieht ein Investitionsgut so lange und so genau wie eine Leasing-Gesellschaft. Sie kauft es für den Kunden, kalkuliert seinen Wert über die Laufzeit, bietet ergänzende Services rund um die Nutzung an, nimmt es zurück und verwertet es. Die Objektnähe ist der Kern des Geschäftsmodells und seit Jahrzehnten handwerkliches Wissen: Bewertungserfahrung, Know-how von Objekten, Märkten sowie Verwertungskanälen. Zu dieser Erfahrung kommen jetzt Daten aus dem Objekt selbst.



DR. CLAUDIA CONEN

ist Hauptgeschäftsführerin des Bundesverbandes Deutscher Leasing-Unternehmen, Berlin.

Vernetzte Maschinen melden in vielen Objektklassen laufend Betriebsstunden, Zustand, Standort und Fehlercodes. Wer diese Daten hat, legt seiner Restwertkalkulation die tatsächliche Nutzung zugrunde statt Alter und Typ. Wer sie nicht hat, rechnet weiter mit pauschalen Erfahrungswerten.

Datenzugang durch den Data Act der EU

Der Datenzugang ist inzwischen keine reine Verhandlungssache mehr. Lange galt: Telemetriedaten gehören dem Hersteller, alles Weitere ist Verhandlung. Die europäische

Datenverordnung Data Act hat das verändert, und zwar in zwei Stufen:

Seit dem 12. September 2025 haben Nutzer Anspruch auf Zugang zu den Produkt- und Dienstdaten, die ohne Weiteres verfügbar sind. Dieser Anspruch gilt auch für die Bestandsflotte, sobald der Dateninhaber die Daten ohnehin vorhält, etwa im Herstellerportal. Zusätzlich gilt seit dem 12. September 2026 die Konstruktionspflicht: Vernetzte Produkte, die danach in Verkehr gebracht werden, müssen den Zugang von vornherein vorsehen, standardmäßig und unentgeltlich. Bestandsobjekte müssen dafür nicht umgebaut werden.

Für Leasing-Gesellschaften ist die erste Stufe die praktisch wichtigere. Sie betrifft den Bestand, also das Portfolio, das heute in den Büchern steht. Zuständig für die Aufsicht in Deutschland ist die Bundesnetzagentur.

Entsprechende vertragliche Vereinbarungen werden durch den Data Act nicht überflüssig. Der gesetzliche Anspruch erfasst nur Daten, die beim Dateninhaber ohnehin "ohne Weiteres verfügbar" vorliegen. Eine Pflicht, Daten extra zu erheben oder aufzubereiten, besteht nicht. Zwar macht das Gesetz einige Mindestvorgaben zu Format und Häufigkeit: Die Bereitstellung muss unentgeltlich, in einem strukturierten, gängigen, maschinenlesbaren Format erfolgen und – soweit technisch möglich – kontinuierlich beziehungsweise in Echtzeit. Offen bleiben jedoch die konkrete technische Umsetzung (welche Schnittstelle, welches Dateiformat, welche Aktualisierungsintervalle im Einzelnen) sowie vor allem, wie lange die Bereitstellung über welchen Zeitraum hinweg geschuldet ist. Das regelt der Data Act nicht und muss vertraglich festgelegt werden.

Auch die Weitergabe an Dritte, etwa an Gutachter oder Verwerter, ist zwar dem Grunde nach vorgesehen, ihre konkrete Ausgestaltung erfolgt aber ebenfalls erst vertraglich zwischen Dateninhaber und Drittem und will entsprechend eigenständig geregelt sein. Wer das erst klärt, wenn er die Daten tatsächlich benötigt, verhandelt aus der schwächeren Position.

Wo der Nutzen entsteht

Der Nutzen verteilt sich auf vier Felder. Zustands-, Nutzungs- sowie Standortdaten machen Ausfall- und Verwertungsrisiken früher sichtbar. Reale Betriebsstunden statt Pauschalannahmen schärfen die Restwertkalkulation und Wartungsdaten erlauben vorausschauende Wartung (Predictive Maintenance), statt im Schadensfall zu reagieren. Außerdem eröffnen sie Erträge jenseits der Finanzierungsmarge, über nutzungsabhängige Verträge, Servicepakete und eine Verwertung, die den dokumentierten Zustand belegen kann. Die Daten kommen aus vier Quellen: aus der Maschinensteuerung mit Betriebsstunden, Fehlercodes, Standort und Auslastung, aus den Portalen der Hersteller mit Wartungshistorie sowie Konfigurations- und Softwareständen, aus den eigenen Systemen mit Objektstamm, Vertrags- und Zahlungsdaten sowie Verwertungserlösen, und aus dem Markt mit Gebrauchtpreisen, Branchenindizes und Nachfrageentwicklung.

Die eigentliche Verschiebung: vom Ereignis zum Prozess

Vier Größen verschieben sich. Was bisher zum Vertragsbeginn einmal festgelegt wurde, lässt sich jetzt über die Laufzeit beobachten und nachsteuern.

Objekt- und Kundensicht treffen sich an einer Stelle. Eine Maschine, die über Wochen stillsteht, sagt zunächst etwas über die Auslastung. Sie kann auch ein früher Hinweis auf die Lage des Kunden sein, oft bevor die erste Rate ausbleibt. Dieses Signal tritt neben die Bonitätsprüfung, ohne sie jedoch zu ersetzen.

Ein Hinweis zur Genauigkeit: Messen lässt sich die Nutzung. Der Restwert bleibt eine Prognose, in die Erfahrung und Know-how der Leasing-Gesellschaft einfließen. Sie wird belastbarer, wenn reale Betriebsstunden statt Pauschalannahmen eingehen, aber sie bleibt eine Annahme über einen künftigen Markt.

Ein Leasing-Objekt durchläuft Antrag, Aktivierung, Laufzeit und Rückgabe. In jeder dieser Phasen entstehen Daten: Objektstamm und Identifikation, Seriennummer und Konfiguration, Nutzung und Wartung, Bewertung und Restwertabgleich. Verloren gehen diese Daten an den Übergängen, und dort entstehen auch die Kosten, in Form von Nacharbeit, Rückfragen und Streit über den Zustand bei der Rückgabe.

Was in der Umsetzung trägt

Vier Erfahrungen wiederholen sich in Datenprojekten der Branche.

Datenqualität schlägt Datenmenge, sie gilt als eine der größten Umsetzungshürden, noch vor den Kosten.

Der Engpass liegt in der Organisation: Ohne klar zugewiesene Verantwortung für die Datenpflege verfällt jeder Bestand.

Der Zugang zu Telemetriedaten ist inzwischen gesetzlich abgesichert. Was er nicht regelt, gehört in den Vertrag: Format, Frequenz, Dauer und die Weitergabe an Dritte, mit dem Hersteller und dem Kunden. Zu Beginn sind das wenige Sätze. Später kostet dieselbe Klärung Zeit und Vertrauen.

Und der Nutzen kommt vor der Technik. Wer mit einer konkreten Frage beginnt, etwa warum die Verwertungserlöse einer Objektklasse regelmäßig unter der Kalkulation liegen, weiß hinterher, welche Daten er dauerhaft braucht und welches System er dafür wirklich benötigt. Umgekehrt

Die Phasen eines Leasing-Objektes

Dimension	Bisher	Mit Asset- und Nutzungsdaten
Vertragsmodell	Feste Laufzeit, Pauschalrate	Nutzungsabhängige Raten (Pay-per-Use), flexible Laufzeitanpassung
Risikofrüherkennung (Kunde)	Bonitätsprüfung zum Vertragsbeginn	Zusätzlich laufende Signale aus Nutzung, Zustand und Standort
Restwert (Kalkulation)	Erfahrungswerte und Tabellen	Reale Betriebsstunden, Wartungshistorie, Marktdaten
Steuerung (Objekt)	Eingriff erst bei Störung oder bei Rückgabe	Frühwarnung aus Nutzungsabbrüchen und Anomalien

Quelle: Eigene Darstellung

steht am Ende oft ein teures Datenlager, das niemand mit einer Frage füttert.
Aus den Bruchstellen und diesen Erfahrungen folgen sechs Empfehlungen:

- Ein Objekt, eine ID: eine eindeutige Asset-Identität über alle Systeme hinweg
- Datenrechte als ein fester Bestandteil des Leasing-Vertrags
- Pflege am Entstehungsort, also in Vertrieb, Service und Rückgabe statt nachträglich
- Wenige belastbare Kennzahlen statt eines überfrachteten Dashboards
- Klein starten mit einer Objektklasse als Pilot, Nutzen belegen, dann ausrollen
- Data Ownership im Fachbereich verankern, nicht in der IT allein

Damit das steuerbar wird, muss die Datenqualität selbst messbar sein: über die Vollständigkeit des Objektstamms, die Abdeckung mit vertraglich gesichertem Zugriff und, als Ergebnisgröße, die Abweichung zwischen kalkuliertem und realisiertem Restwert.

Das Eco-System

Kein Beteiligter besitzt alle Daten. Der Hersteller hält technische Daten, Telemetrie und Wartungslogik. Der Finanzierer hält Vertrags-, Zahlungs- und Portfoliodaten sowie Restwert- und Verwertungswissen. Der Betreiber kennt reale Einsatzbedingungen, Auslastung und Bedarfsentwicklung. Der Nutzen entsteht erst im Zusammenspiel.

In dieser Dreierbeziehung hat Leasing eine starke Position: Die Leasing-Wirtschaft kennt das Objekt über den gesamten Lebenszyklus, vom Einkauf über die Nutzung bis zur Verwertung. Diese Asset-Kompetenz kann Leasing zur ersten Wahl machen, wenn Nutzung statt Eigentum gefragt ist.

Was auf die Branche zukommt

Die Objektklassen, um die es künftig geht, haben kurze Technologiezyklen: KI-Hardware, Robotik, softwaredefinierte Ausrüstung. Für sie ist Leasing die naheliegende Zugangsform, weil sich der Kauf bei Geräten mit kurzer Halbwertszeit selten rechnet. Dazu kommt die Berichtspflicht: Verbrauchs- und Lebenszyklusdaten liefern die Nachweise, die Kunden für ihr eigenes Reporting brauchen. Und Rückgabe, Aufarbeitung und Wiedereinsatz werden vom Abwicklungsthema zum Verkaufsargument.

Bei vernetzter, softwaregesteuerter Ausstattung wird schließlich der Datenschutz selbst zum Auswahlkriterium. Wer Standortdaten verarbeitet, braucht Zweckbindung, Aggregation und Löschfristen, weil Rückschlüsse auf Personen möglich sind. Parallel verlangen MaRisk, ESG-Vorgaben und DORA belastbare Daten und nachvollziehbare Modelle. Gewachsene Kernsysteme speichern oft genau die Daten nicht, die heute verlangt werden.

Was jetzt zu tun ist

Datenrechte, die der Data Act offenlässt, gehören schon heute in jeden neuen Vertrag. Dieser Schritt lässt sich später am schwersten nachholen. Wer die Nutzung eines Objekts erst kennen will, wenn die Rückgabe ansteht, verhandelt aus der schwächeren Position. Der zweite Schritt ist ein sauberer Objektstamm. Der dritte ist Geduld: Datenpflege zeigt erst Wirkung, wenn sich die ersten Rückgabejahrgänge mit den ursprünglichen Kalkulationen vergleichen lassen.

Bemerkenswert an der Datendebatte ist, wie wenig sie letztlich mit Technik zu tun hat. Sie entscheidet sich im Vertrag, in der Zuständigkeit und in der täglichen Routine der Fachbereiche. Wer das Objekt kennt, kalkuliert präziser, berät qualitativ hochwertiger und verwertet erfolgreicher. Das war schon immer die Stärke des Leasings. Sie hat jetzt eine erweiterte Grundlage.

Das Potenzial von IoT-Daten im Underwriting

Die Versicherungswirtschaft verfügt heute über mehr Daten als es jemals zuvor der Fall gewesen ist. Industrieanlagen liefern kontinuierlich Informationen über ihren Betriebszustand, Sensoren überwachen kritische Komponenten in Echtzeit und künstliche Intelligenz erkennt Auffälligkeiten lange, bevor sie zu einem Ausfall führen. Dennoch basiert das Underwriting vieler Industrieversicherer noch immer auf statischen Informationen, historischen Schadendaten und jährlichen Vertragszyklen.

Zwischen technischer Realität und versicherungstechnischer Entscheidungsfindung klafft damit eine Lücke. Während Betreiber IoT-Daten längst nutzen, um Anlagen effizienter und sicherer zu betreiben, fließen diese Erkenntnisse in vielen Fällen kaum in die Risikobewertung von Versicherern ein.[1]

Das Ende des statischen Underwritings

Über Jahrzehnte beruhte Underwriting auf einer einfachen Logik: Risiken werden zu einem bestimmten Zeitpunkt bewertet, kalkuliert und bis zur nächsten Vertragsverlängerung weitgehend unverändert betrachtet. Dieses Vorgehen funktionierte in einer Welt, in der sich Risiken nur langsam veränderten und ausreichend historische Schadendaten verfügbar waren.

Heute sieht die Realität anders aus: Industrieanlagen werden komplexer, Betriebszustände verändern sich kontinuierlich und neue Technologien entwickeln sich schneller, als Erfahrungswerte entstehen können – man denke zum Beispiel an Batterietechnologie. Risiken sind damit zunehmend dynamisch – die Bewertungsmodelle vieler Versicherer hingegen nicht.

IoT-Daten ermöglichen einen kontinuierlichen Blick auf den tatsächlichen Zustand versicherter Anlagen. Damit entsteht die Chance, Underwriting von einer statischen Momentaufnahme zu einem datenbasierten, dynamischen Entscheidungsprozess weiterzuentwickeln. Risiko wird nicht mehr ausschließlich zum Vertragsbeginn bewertet, sondern kann entlang des gesamten Lebenszyklus einer versicherten Anlage beobachtet und eingeordnet werden.



CHRISTOPH BAUER

ist Manager des HDI TH!NX Campus in Berlin.

Die größte Hürde ist die Umsetzung

Dass Sensoren, IoT-Plattformen und KI große Datenmengen erzeugen und verarbeiten können, ist heute kaum noch die eigentliche Herausforderung. Sensorik und Analysewerkzeuge sind komplex und nicht zu unterschätzen, aber sind für Versicherer nicht der wirkliche Engpass. Die entscheidenden Hürden liegen darin, IoT-Daten in bestehende Strukturen, Verträge und Entscheidungsprozesse der Versicherer zu integrieren. Die Technik kann liefern, nur der Change in jahrzehntelang gewachsenen Strukturen, der lässt sich nicht automatisieren.

Historisch gewachsene Prozesse, organisatorische Strukturen und unterschiedliche Anforderungen der beteiligten Fachbereiche erschweren vielerorts den Schritt von verfügbaren Daten zu ihrer tatsächlichen Nutzung im Underwriting. Die Abbildung zeigt fünf zentrale Hürden für die praktische Umsetzung.

Aus Daten müssen Entscheidungen werden

Dabei liegt der eigentliche Wert von IoT nicht in der schieren Datenmenge. Millionen Sensormessungen verbessern keine Risikobewertung, solange sie nicht in eine Form übersetzt werden, die im Underwriting unmittelbar nutzbar ist. Entscheidend ist die Transformation technischer Betriebsdaten in für das Underwriting relevante Risikoindikatoren. Erst wenn aus Temperaturverläufen, Schwingungsmustern oder Ladezyklen konkrete Aussagen über Risikotrends, Wartungsqualität oder potenzielle Schadenursachen entstehen, können IoT-Daten zu einer belastbaren Entscheidungsgrundlage werden. Dabei geht es nicht darum, einzelne Messwerte isoliert zu betrachten. Entscheidend sind Veränderungen, Muster und Abweichungen, die Rückschlüsse auf den Zustand einer Anlage und die Entwicklung eines Risikos zulassen.

Diese Risikoindikatoren können unterschiedlichste Prozesse unterstützen – von der Prämienkalkulation und Kapazitätsentscheidung über Vertragsklauseln und vertragliche Obliegenheiten bis hin zu Schadenmanagement, Vertragsverlängerungen und strategischer Portfoliosteuerung. Die Breite an Anwendungsmöglichkeiten zeigt leider auch den Aufwand, der intern betrieben werden müsste, um diese zu nutzen. Der eigentliche Mehrwert entsteht nicht durch mehr Daten, sondern durch deren Kontextualisierung. Oder anders formuliert: Nicht das Sensorsignal ist entscheidend, sondern seine Übersetzung in Versicherungssprache.

BESS: Transparenz für neue Risiken

Wie groß dieses Potenzial ist, zeigt sich besonders deutlich bei Batterie-Energiespeichersystemen (Battery Energy Storage

Zentrale Hürden bei der Nutzung von IoT-Daten



Gewachsene Prozesse
Statische Abläufe erschweren die Integration kontinuierlicher Daten



Datensilos
Relevante Informationen sind nicht durchgängig verfügbar



Fehlende Schnittstellen
IoT-Daten sind nicht ausreichend mit Kernsystemen verbunden



Organisatorische Trennung
Underwriting, IT, Data Science und Risk Engineering arbeiten getrennt



Fehlender Business Case
Technische Möglichkeiten werden nicht konsequent mit konkreten Entscheidungen verknüpft

Quelle: Eigene Darstellung auf Basis des Whitepapers

Systems, BESS). Die Herausforderungen in Batterie-nahen Umfeldern sind den Kfz-Finanzierern und Leasing-Anbietern wohlbekannt – man denke an die Restwertproblematik und die teils widersprüchlichen Aussagen zu Langlebigkeit und Second Use – im industriellen Maßstab kommen aber noch höhere Sicherheitsbedenken zur Geltung.

Der BESS-Markt wächst weltweit mit hoher Dynamik und entwickelt sich zu einer tragenden Säule der Energiewende. Gleichzeitig stellen Batteriespeicher Versicherer vor neue Herausforderungen: Produktionsprozesse und technische Grundlagen verändern sich schnell, Betriebserfahrungen sind noch begrenzt und historische Schadendaten reichen häufig nicht aus, um Risiken zuverlässig zu bewerten. Jedes Jahr rollen neuartige Zellen und Module von ebenso unerprobten Produktionsanlagen. Ein bis zwei Grad Temperaturunterschied in einem Prozessschritt können zu strukturellen Defekten führen. Kommt es später im Betrieb zu einem Schaden, können die Auswirkungen erheblich sein. Für das Underwriting entstehen dadurch sogenannte Black Box-Risiken: Anlagen, deren tatsächlicher technischer Zustand nur eingeschränkt nachvollziehbar ist.

IoT-basierte Zustandsüberwachung bietet hier einen neuen Ansatz. Betriebsdaten aus Batteriemanagementsystemen geben Einblicke in den Zustand einzelner Speicher, ermöglichen es, kritische Entwicklungen frühzeitig zu erkennen, und schaffen Transparenz über Risiken, die bislang verborgen blieben. Damit wird ein bislang schwer einschätzbares Risiko kontinuierlich beobachtbar und lässt sich fundierter bewerten.

IoT als Teil des Versicherungsprozesses

Die Versicherungswirtschaft muss bei der Integration von IoT-Daten nicht bei null anfangen. In verbrauchernahen Versicherungssparten zeigen Präzedenzfälle, wie sich kontinuierlich erhobene Daten in Versicherungsprozesse integrieren lassen. Insbesondere in der Autoversicherung hat sich Telematik zu einem etablierten Bestandteil datenbasierter Versicherungsmodelle entwickelt. Fahrverhalten und Nutzung können direkt in Risikobewertung und Preisgestaltung einfließen. Besonders für junge Fahrer, die noch keine Historie haben, kann Telematik helfen, Risiken auch ohne Schäden zu bewerten – und somit profilgenauer zu bepreisen. Auch in der Kranken- und Lebensversicherung werden Daten vernetzter Geräte für Präventions- und Bonusprogramme eingesetzt – Smartwatches und Co werden von manchen Versicherern sogar subventioniert. Ihre Verbreitung ist dort jedoch bislang geringer als bei Telematikanwendungen in der Autoversicherung. Diese Beispiele zeigen: IoT schafft vor allem dann Mehrwert, wenn aus Daten konkrete Entscheidungen und Handlungen entstehen. Für das industrielle Underwriting lassen sich daraus zentrale Prinzipien ableiten:

- **Mit konkreten Anwendungsfällen beginnen:** Statt eine umfassende technische Infrastruktur aufzubauen, sollten Versicherer definieren, welche Entscheidung durch zusätzliche Daten verbessert werden soll. Das kann die Risikoselektion, die Preisgestaltung, die Festlegung von Vertragsbedingungen oder die Bewertung bei einer Vertragsverlängerung sein.

- **Daten in relevante Risikoindikatoren übersetzen:** Im Underwriting werden keine zusätzlichen Datenströme, sondern verständliche und vergleichbare Informationen benötigt. Technische Betriebsdaten müssen in standardisierte Risikoindikatoren übersetzt werden, die sich unmittelbar in bestehende Entscheidungsprozesse integrieren lassen.

- **IoT in bestehende Prozesse integrieren:** Ein zusätzliches Dashboard allein verändert noch kein Underwriting. Die gewonnenen Erkenntnisse müssen dort verfügbar sein, wo Entscheidungen getroffen werden – vom Underwriting und Risk Engineering über Schadenmanagement und Vertragsverlängerung bis zur Portfoliosteuerung.

- **Fachbereiche zusammenbringen:** IoT-basiertes Underwriting ist keine reine IT-Aufgabe. Underwriting, Risk Engineering, Data Science, IT und weitere Funktionen sollten bei der Entwicklung eines Anwendungsfalls festlegen,

welche Daten benötigt werden und wie daraus versicherungstechnisch nutzbare Informationen entstehen.

- **Vertragsgestaltung an die Datennutzung anpassen:** Wenn kontinuierliche Zustandsdaten in die Risikobewertung einfließen, müssen die vertraglichen Rahmenbedingungen darauf abgestimmt werden. Dazu gehören klare Datenklauseln, sensorbasierte Obliegenheiten und definierte Reaktionsregeln, falls Risikoindikatoren auf eine kritische Entwicklung hinweisen. So wird festgelegt, welche Daten bereitgestellt werden, wie mit Warnsignalen umzugehen ist und welche Maßnahmen daraus folgen. Das Problem, dass oftmals Warnungen über den Zustand von Assets vorliegen, diese aber nicht zeitgerecht in Aktionen münden, muss hier mitgedacht werden.

- **Risikoindikatoren entwickeln:** Versicherer sind bei IoT-Anwendungen auf Daten und technisches Wissen von Anlagenbetreibern, Herstellern und Technologieanbietern angewiesen. Entscheidend ist die gemeinsame Entwicklung der relevanten Risikoindikatoren. Technische Messgrößen müssen mit versicherungstechnischem Wissen verknüpft werden, damit aus verfügbaren Betriebsdaten belastbare Aussagen für die Risikobewertung entstehen.

- **Erfolg messbar machen und schrittweise skalieren:** Anwendungen sollten an klar definierten geschäftlichen Kennzahlen gemessen werden. Ist ein konkreter Mehrwert nachgewiesen, können erfolgreiche Ansätze schrittweise auf weitere Risiken, Assets oder Portfolios übertragen werden. Der nächste Schritt besteht darin, erfolgreiche Ansätze aus einzelnen Anwendungsfällen systematisch in die Breite zu übertragen. IoT sollte nicht als isolierte technische Lösung, sondern als Bestandteil der Risikobewertung und -steuerung verstanden werden. Wenn die gewonnenen Erkenntnisse tatsächlich Underwriting-Entscheidungen beeinflussen, wird aus technischer Datenverfügbarkeit ein versicherungstechnischer Mehrwert.

Relevanz für Finanzierung und Leasing

Die beschriebene Logik lässt sich auf Finanzierung in Form von Kredit und Leasing übertragen. Zustands- und Betriebsdaten schaffen nicht nur für Versicherer zusätzliche Transparenz, sondern auch Hinweise auf die Wartungsqualität, die technische Beanspruchung und mögliche Ausfallrisiken finanzierter Anlagen liefern. Damit können sie eine zusätzliche Informationsgrundlage für die laufende Bewertung eines finanzierten Objekts schaffen.

Besonders relevant kann dies bei langlebigen und technisch komplexen Anlagen sein, deren Zustand und Nutzung Einfluss auf Ausfallrisiken und Restwertentwicklung haben. Ergänzen kontinuierliche Betriebsdaten die bislang überwiegend punktuelle Bewertung, können Veränderungen früher sichtbar werden. Für Banken und Leasing-Gesellschaften eröffnet sich damit perspektivisch die Möglichkeit, technische Risiken über die Vertragslaufzeit transparenter zu beobachten und in die eigene Risikobewertung einzubeziehen. Generell handelt es sich hier um zwei Seiten derselben Medaille: Denn ein Finanzdienstleister finanziert erst, wenn mindestens ein Versicherer überzeugt ist.

Von Daten zu besseren Entscheidungen

Die Industrieversicherung steht vor einem Wandel. Sensorik und neue Möglichkeiten der Datenanalyse schaffen die Grundlage für ein stärker datenbasiertes Underwriting. Entscheidend wird künftig sein, diese Möglichkeiten in bestehende Prozesse zu integrieren und aus operativen Anlagendaten konkrete versicherungstechnische Mehrwerte abzuleiten.

IoT verändert Underwriting damit nicht durch mehr Informationen, sondern durch eine neue Qualität der Risikobewertung. Versicherer, denen es gelingt, technische Daten in verständliche, standardisierte und entscheidungsrelevante Risikoindikatoren zu übersetzen, schaffen die Grundlage für dynamischere, transparentere und belastbarere Underwriting-Entscheidungen. Die Zukunft des Underwritings beginnt deshalb nicht mit der nächsten Sensorik-Generation oder noch granulareren IoT-Daten – sondern mit der Fähigkeit, vorhandene Daten in bessere Entscheidungen zu übersetzen.

Fußnoten:
1) Genau diese Diskrepanz steht im Mittelpunkt des Whitepapers Unlocking the Value of IoT Data in Underwriting, das gemeinsam vom HDI TH!NX Campus, PROTH!NX und dem IoT Insurance Observatory veröffentlicht wurde.

Pay-per-Outcome, Risiko-Management und Fleet Learning

„Beherrschtes Risiko übersetzt sich in Marge." Die Aussage vom ehemaligen Atos-Vorstand Thierry Breton behält bis heute ihre Gültigkeit. Thierry Breton brachte damit ein fundamentales Prinzip der IT-Service-Erbringung auf den Punkt. Ein Rückblick verdeutlicht die Dynamik: Mit dem Hosting eines einfachen Servers war damals bereits kaum Geld zu verdienen – im IT-Commodity-Bereich lag die Spanne bei circa fünf bis acht Prozent. Brauchte ein Kunde jedoch ein hochredundantes System – etwa für eine kritische Anwendung im Produktionsumfeld mit hochverfügbarer Datenbank über zwei getrennte Rechenzentren hinweg –, lag darin erheblicher betriebswirtschaftlicher Wert, da das Ausfallrisiko der Kundenproduktion drastisch reduziert wurde.

Heute sind Rechenzentren und Cloud-Hyperscaler-Services derart ausfallsicher ausgelegt, dass sich für klassische IT-Infrastruktur-Dienstleister kaum noch Auskömmlichkeit erzielen lässt. Die Wertschöpfung hat sich auf den Hyperscaler verschoben.

Anwendungsfälle aus der Praxis

Siemens Energy (bald: Omterra) vertreibt seit etlichen Jahren Turbinen Outcome-basiert. Der durch eine massive IoT-Architektur unterfütterte Ansatz ermöglicht es, Turbinen auf Basis von aus Daten kondensiertem Erfahrungswissen hocheffizient zu betreiben.

Ein Praxisbeispiel: Ein Kunde aus der Prozessindustrie nutzt die Abwärme seiner Anlage zur Stromerzeugung. Die Anlage wird nur einmal alle 24 Monate abgeschaltet. Siemens Energy berechnet mittels Digital-Twin-Technologie die „Remaining Useful Lifetime" aller Verschleißteile und tauscht diese kosteneffizient im vorgegebenen Wartungsfenster aus. Träte ein unerwarteter Ausfall ein, würde Siemens Energy die Kosten der entgangenen Stromerzeugung tragen. Risikobeherrschung wird hier direkt monetarisiert. Hingegen zeigt das Beispiel der Firma Trumpf im Bereich der Metallbearbeitungsmaschinen („Pay per Part") die Hürden auf. KI spielte hier bei der Materialversorgung und -entnahme eine Schlüsselrolle, um Maschinen im Mehrschichtbetrieb mit minimaler Aufsicht zu betreiben. Neben der Umwandlung von Investitionsaufwand (CapEx) in variable Betriebskosten (OpEx) traten in der Praxis jedoch wesentliche Hemmnisse auf:

- **Finanzierungskosten und Parteienvielfalt:** Gewerbliche Kunden erkennen schnell, dass Modelle mit Leasing- und Bankenbeteiligung die Anzahl der beteiligten Parteien erhöhen. Bei ausreichender eigener Liquidität ist die Direktinvestition meist günstiger als das Margen-Stacking über mehrere Firmen hinweg.
- **Zielgruppen-Fehlallokation:** Kunden, die rein aufgrund von Liquiditätsengpässen auf ein OpEx-Modell angewiesen sind, stellen aus Bonitäts- und Risikoperspektive oft keine bevorzugte Zielgruppe dar.
- **Das Auslastungsrisiko als Kernproblem:** Das Hauptrisiko aus Kundensicht ist nicht primär die Maschinenstillstandszeit, sondern die Unterauslastung der Kapazitäten. Dieses Marktrisiko lässt sich im traditionellen Setup nicht ohne Weiteres auf den Hersteller übertragen.

Um Kunden das Risiko der Maschinenunterauslastung abzunehmen, müsste ein herstellerübergreifendes Auftrags-Brokering etabliert werden – was wiederum an das kulturelle und rechtliche Bollwerk der Datensouveränität stößt: Welches Unternehmen gewährt seinem Maschinenlieferanten freiwillig Einblick in die Auftragsbücher?

Die Rolle von Fleet Learning

Eine Gemeinsamkeit der Daten- und Analytik-basierten Übernahme von Kundenrisiken in Rahmen von Outcome-as-a-Service-Modellen ist häufig, dass das Einzelrisiko eines Endkunden statistisch zu selten ist, um lokal eine zuverlässige KI zu trainieren. Erst die Skalierung über die gesamte Flotte eines Service-Anbieters hinweg ermöglicht es, seltene Fehlerzustände ("Black Swan Events") vorherzusehen und zuverlässig abzusichern.

Schauen wir uns hier drei Fleet-Learning-Anwendungsfälle an:

- **Windkraftanlagen:** Ein einzelner Parkbetreiber verfügt oft nur über wenige Dutzend Windkraftanlagen. Wenn dort ein seltenes mechanisches Fehlermuster (zum Beispiel Mikrorisse im Hauptlager durch ungleichmäßige Böen) auftritt, reicht die lokale Datenbasis meist nicht aus, um das Schadensbild vor dem physischen Kollaps zu erkennen. Ein Getriebetausch auf See erfordert Errichterschiffe und verursacht Millionenkosten sowie lange Ausfallzeiten.



BORIS SCHARINGER

verfügt über langjährige Erfahrung im IT- und Innovationsmanagement mit besonderem Fokus auf industrielle KI.

Der Beitrag von Fleet Learning: Der Turbinenhersteller aggregiert Vibrations-, Temperatur- und Belastungsdaten aus Tausenden weltweit installierten Anlagen in einem anonymisierten Flottenmodell. Erkennt die KI in einem Windpark in der Nordsee ein neuartiges Anzeichen für einen drohenden Lagerdefekt, wird dieses Wissen sofort auf Anlagen im Atlantik oder im Pazifik übertragen.

Risikominimierung: Vermeidung katastrophaler Ausfälle (Totalverlust) und Reduktion ungeplanter Stillstandzeiten.

- **Spritzgießen:** Kunststoffe unterliegen je nach Recyclinganteil oder Lieferanten Batch-Schwankungen im Viskositäts- und Thermoverhalten. Bei hochpräzisen Teilen (zum Beispiel Medizinspritzen oder Steckverbindern) führt eine falsche Druck- oder Temperatureinstellung zu unsichtbaren Hohlräumen oder Beschädigungen der teuren Werkzeuge.

  Der Beitrag von Fleet Learning: Maschinenhersteller nutzen datengestützte Assistenzsysteme, die kontinuierlich Druckkurven, Schmelze-Temperaturen und Werkzeuginnendrücke über die gesamte weltweit installierte Maschinenflotte hinweg analysieren. Das Flottenmodell lernt, wie sich bestimmte Materialcharakteristiken ankündigen und welche Kombinationen aus Druck und Temperatur das Werkzeug schützen.

  Risikominimierung: Minimierung von teurem Ausschuss sowie Schutz der Präzisionswerkzeuge.

- **Nutzfahrzeug-Flotten:** Ein einzelnes Logistikunternehmen fährt mit seinen Lkw meist wiederkehrende Routen. Seltene Ereignisse – wie Blitzeis an einer bestimmten Steigung oder ungewöhnliche Blendeffekte bei tiefstehender Sonne – erlebt ein einzelnes Fahrzeug vielleicht nur alle paar Jahre.

  Der Beitrag von Fleet Learning: Telematik- und Assistenzsysteme erfassen anonymisiert kritische Bremsmanöver, Ausweichaktionen und Sensordaten (Kamera, Radar, LIDAR) aller vernetzten Lkw. Sobald ein Fahrzeug in einer spezifischen Region auf eine seltene Kombination aus Nebel und Straßenglätte trifft und die KI ein optimales Ausweich- oder Bremsmuster erlernt, steht dieses aktualisierte Fahrverhalten allen anderen Lkw weltweit per Over-the-Air-Update zur Verfügung.

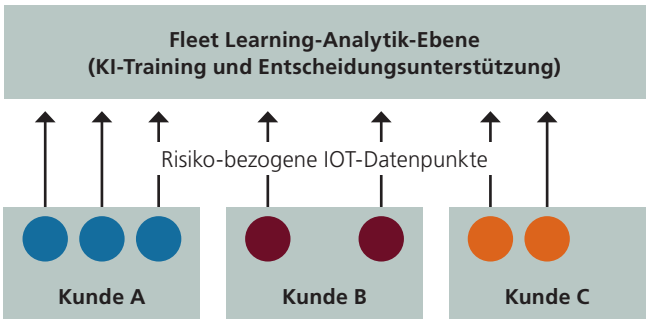
  Risikominimierung: Signifikante Senkung des Unfallrisikos (Haftungs- und Personenschäden) sowie Reduktion von Ausfallzeiten im Güterkraftverkehr.

Fleet Learning braucht Sicherheit

Was sind aber Voraussetzungen für ein Service-Modell mit kundenübergreifendem Fleet Learning? Die Bereitschaft der Kundschaft, aus dem eigenen Betrieb Daten zur Verfügung zu stellen. Zunächst lässt sich das Risikoprofil einer Datenbereitstellung aus Kundensicht in zwei Themenblöcke strukturieren:

Erfolgreiches Fleet Learning benötigt Absicherungsmechanismen

Analytik-Absicherungsebene
(z. B., vertrauenswürdige KI-Implementierung, Rückversicherung, …)



Datenzugriffs-Absicherungsebene
(z. B., Data Spaces, verteiltes maschinelles Lernen, vertragliche Vereinbarungen)

Quelle: Eigene Darstellung

- Verlust von Intellectual Property (IP), also die Sorge, differenzierendes Know-How preiszugeben.

- Verlust weiterer Geschäftsgeheimnisse: IOT-Daten können nicht-IP-bezogene Geschäftsgeheimnisse enthalten. Beispiel: Das Monitoring der Lkw-Flotte legt die eigenen Lieferanten- oder Kundenbeziehungen offen. Oder eine "Flaschenhals"-Maschine gibt über Time Stamps Produktionsdurchsatz preis.

Der Umgang mit diesem Risikoprofil im Datenteilen macht wiederum einen wesentlichen Teil der Differenzierung des Fleet-Learning-Providers aus:

- Ehrlichkeit in der Diskussion, was überhaupt differenziert. Dieser Aspekt ist sicherlich der vertrieblich gesehen langwierigste: Es gilt das diffuse Gefühl der Geschäftsführung auf Kundenseite durch eine ehrliche Bestandsaufnahme zu ersetzen, was wirklich schützenswert ist. Beispiel: Sicherlich nicht ein Platinen-Design, das jedem Wettbewerber durch Aufschrauben des Produkts zugänglich ist.

- Anonymisierungsverfahren befreien IOT-Daten von IP und liefern trotzdem ein risikominimierendes KI-Modell. Vereinfachtes Beispiel: Die vorausschauende Wartung einer CNC-Maschine erfordert als Datenpunkt die Summe aller Bewegungen der CNC-Achsen ("Achsenmotorenleistung"). Durch die Übermittlung lediglich der aggregierten Bewegungen ist ein Reengineering der Werkstücke, die über diese Maschine liefen, unmöglich.

- Föderierte KI-Trainingsverfahren ("federated learning") lassen die Daten lokal, trainieren eine Vielzahl lokaler

KI-Modelle und bauen Fleet Learning-Logik über eine Aggregation der vielen dezentral trainierten Modelle auf. Übrigens: Alle unsere Mobiltelefone arbeiten so im Bereich der Textergänzungs-KI (zum Beispiel T9).

- Datenökosysteme mit festgelegter Geschäftsordnung, Vertragsstruktur und Eskalationswegen, wie zum Beispiel die X-Initiativen (Catena-X, Manufacturing-X, …), schaffen "neutrale" Verbindlichkeit.

- Last but not least: Persönliche Verantwortlichkeit ("Accountability") verankern: Wohin wende ich mich, wenn ich den Eindruck habe, es geht etwas schief? Dies ist ein heute noch unterschätzter Faktor mit hohem Einfluss auf Kundenbereitschaft, Daten zu teilen.

Implikationen für Unternehmen

Besondere Herausforderungen ergeben sich, wenn junge Technologieunternehmen versuchen, Risiken des Kunden zu übernehmen. Ein Start-up entwickelt beispielsweise einen KI-basierten Ansatz zur vorausschauenden Wartung von Antriebssträngen. Lassen sich Start-up-Gründer zähneknirschend auf Kundenverträge ein, die Fleet Learning untersagen, wird dem Geschäftsmodell des Start-Ups die Skalierungsgrundlage entzogen – das Start-up wird auf einen Projektdienstleister reduziert.

Für Kunden eines Start-Ups mit Risikoübernahme-Wertversprechen stellt sich hingegen die Frage der Partnerfragilität: Tritt der Garantiefall ein, muss der risikotragende Partner auch finanziell in der Lage sein, die Kompensationsleistung zu erbringen. Bilanzielle Rückstellungen stellen für ein junges Unternehmen eine erhebliche Belastung dar.

In diesem Kontext gewinnen spezialisierte Absicherungsinstrumente an Bedeutung. Angebote wie aiSure™ von Munich Re bieten Rückversicherungslösungen, um Outcome-basierte Geschäftsmodelle gegen Performanceeinbrüche in KI-Algorithmen abzusichern.

Für Start-ups reduziert dies den bilanziellen Rückstellungsbedarf drastisch. Auch für etablierte Leasing-Geber und Factoring-Institute ist die Analyse solcher Risikoprofile wertvoll, um neue Finanzierungsstrukturen risikoadäquat zu bepreisen.

Kernpunkte für die Praxis

- **'CapEx zu OpEx' reicht als Argument nicht aus:** Die reine Umwandlung von Investitions- in Betriebskosten ist ein buchhalterischer Begleiteffekt, aber kein hinreichendes Differenzierungsmerkmal auf dem europäischen Markt.

- **Risikoübernahme erfordert Analysekompetenz:** Die Fähigkeit, verlässliche Garantien abzugeben, wächst direkt mit der Qualität der KI-Modelle und der zugrunde liegenden Datenbasis.
- **Fleet Learning als Wettbewerbsvorteil:** Erst die kundenübergreifende Nutzung von Trainingsdaten bildet die Grundvoraussetzung, um Risiken besser zu beherrschen als es ein einzelner Kunde selbst kann.

- **Absicherungsmechanismen** sowohl auf der Datenzugriffs- wie auch der Analytikebene bilden die Ausgangsbasis für Akzeptanz des Fleet Learning-Ansatzes beim Kunden.

Hinweis für Leser: Eine ausführliche Vorstellung eines Betreibermodells und zur Übernahme systemischer Risiken am Beispiel des Schienenverkehrs finden Sie in unserer früheren Ausgabe (vgl. *Finanzierung-Leasing-Factoring, Ausgabe 06/2025, S. 12–14, "Flexible Zugvermietung"*).

KI braucht Führung ohne Mikromanagement

Die Nutzung von KI wächst rasant. Dennoch bleiben viele Unternehmen in dezentralen Pilotprojekten stecken. Der Engpass liegt selten allein in Technologie oder Daten. Von Bedeutung ist auch eine Führungskultur, die sichere Räume zum Ausprobieren schafft und Mitarbeitende zum Mitdenken befähigt, statt sie auf detaillierte Anweisungen warten zu lassen.

Die Erwartungshaltungen von Organisationen an Künstliche Intelligenz ist hoch. PwC beziffert das Potenzial von KI bis 2035 auf bis zu 15 zusätzliche Prozentpunkte globaler Wirtschaftsleistung. Der Stanford AI Index weist für 2024 weltweite Unternehmensinvestitionen in KI von 252,3 Milliarden US-Dollar aus. Ende 2025 berichteten 88 Prozent der Befragten einer McKinsey-Studie, dass ihre Organisation KI regelmäßig in mindestens einer Geschäftsfunktion nutzt. Zugleich hatte erst rund ein Drittel mit der unternehmensweiten Skalierung begonnen.[1,2,3]

Diese Zahlen markieren die eigentliche Managementaufgabe. Aufmerksamkeit, Budgets und erste Anwendungen sind vielerorts vorhanden. Was fehlt, ist die Übersetzung punktueller Nutzung in echten und wiederkehrenden Geschäftswert. Ein Chatbot im Kundenservice, ein Modell zur Dokumentenextraktion oder ein Assistent für Kreditanalysen kann einen sinnvollen Use Case darstellen. Daraus folgt jedoch noch keine KI-Transformation.

Ein KI-Projekt ist ein zeitlich begrenztes, klar abgegrenztes Vorhaben für einen konkreten Anwendungsfall. Eine KI-Transformation bezeichnet dagegen den unternehmensweiten, dauerhaften Umbau von Strategie, Wertschöpfung, Prozessen, Kultur, Arbeitsweisen, Daten- und Technologieplattformen sowie Governance. Ihr Ziel ist, KI systematisch in das Geschäftsmodell und in die operative Leistungserbringung zu integrieren, zu skalieren und wiederkehrenden Wert zu erzeugen. Diese Perspektive verbindet die Transformationslogik von Holmström und Magnusson mit dem von McKinsey beschriebenen „Rewiring“ von Arbeitsabläufen und Organisationsstrukturen.[4,5]



PROF. DR. BENJAMIN JÄCKLIN

ist Senior Manager bei Kienbaum im Bereich Leadership und Transformation.

Der Unterschied ist groß: Projekte lassen sich beauftragen, aber Transformation ändert, wie eine Organisation entscheidet, zusammenarbeitet, lernt und Verantwortung verteilt.

Führung und AI Transformation

Die typischen Blockaden einer umfassenden AI Transformation lassen sich in sechs Feldern bündeln: Strategie, Aufbau- und Ablauforganisation, Datenfundament, Skills, Recht und Compliance sowie Unternehmenskultur. Die Felder hängen eng zusammen. Eine unklare Strategie führt zu einem beliebigen Use-Case-Portfolio. Schwache Prozessverantwortung verhindert die Integration in End-to-End-Abläufe. Fehlende Datenqualität begrenzt die Leistung der Modelle. Unzureichende Kompetenzen erzeugen Abhängigkeit von wenigen Spezialisten. Eine Kultur mit geringer Fehlertoleranz erstickt Experimente, bevor echte Lernkurven entstehen.

Führung wirkt quer zu allen sechs Feldern. Führungskräfte priorisieren Wertfelder, geben Ressourcen frei, klären Entscheidungsrechte, schaffen Verbindlichkeit und übersetzen abstrakte Strategie in konkrete Erwartungen. Zugleich prägen sie den sozialen Kontext, in dem Mitarbeitende KI erproben. Aktuelle Kompetenzmodelle betonen deshalb die Verbindung aus technologischem Verständnis, strategisch-betriebswirtschaftlicher Urteilskraft, sozialer Kompetenz sowie Lern- und Anpassungsfähigkeit.[6]

AI Anxiety ist Führungsaufgabe

KI verändert Tätigkeiten, Entscheidungsprozesse und professionelle Rollen. Damit berührt sie die berufliche Identität. Beschäftigte fragen sich mitunter: Welchen Wert hat meine Erfahrung, wenn ein Modell Teile meiner Arbeit schneller erledigt? Welche Aufgaben bleiben? Wer trägt die Verantwortung für eine Entscheidung? Wird künftig fachliche Qualität honoriert oder vor allem Geschwindigkeit?

Die Forschung zu AI Anxiety beschreibt Sorgen, die über einen Arbeitsplatzverlust hinausgehen. Dazu gehören ein Verlust an Selbstwirksamkeit und Kontrolle, Unsicherheit über die eigene Rolle, Misstrauen in Systeme und Institutionen sowie die Sorge, dass Arbeit an Sinn und sozialer Bedeutung verliert. Empirische Befunde zeigen einen doppelten Effekt: KI erhöht Produktivität und Engagement zu erhöhen, kann jedoch Erschöpfung, Work-Life-Konflikte und sinkende Arbeitszufriedenheit auslösen.[7,8,9]

Gutes Change Management setzt vor der Tool-Schulung an. Mitarbeitende brauchen Lernzeit, Beteiligungsmöglichkeiten und sichere Räume, in denen sie Grenzen der Systeme be-

Fünf Delegationsstufen entlang der Dimensionen Ziel und Weg

Stufe	Verantwortung für das Ziel	Verantwortung für den Weg	Modus
5	Mitarbeitende	Mitarbeitende	Mitarbeitende bringen eigenverantwortlich neue Impulse hinsichtlich Zielsetzungen ein und verfolgen diese eigenständig innerhalb eines vereinbarten strategischen Rahmens.
4	Führungskraft und Mitarbeitende gemeinsam	Mitarbeitende	Zielsetzung wird gemeinsam geschärft; der Mitarbeitende ist verantwortlich für den Weg.
3	Führungskraft	Mitarbeitende	Klassische Delegation: Erwartetes Ergebnis ist klar; der Lösungsweg liegt jedoch bei den Mitarbeitenden.
2	Führungskraft	Führungskraft und Mitarbeitende gemeinsam	Die Führungskraft erledigt teilweise die Arbeit ihrer Mitarbeitenden.
1	Führungskraft	Führungskraft	Die Führungskraft löst die Aufgabe faktisch selbst.

Quelle: Eigene Darstellung

nennen können. In diesem Kontext spielt psychologische Sicherheit eine große Rolle. Dies bedeutet, Zweifel zu äußern, fehlerhafte KI-Ausgaben sichtbar zu machen und Annahmen von Vorgesetzten zu widersprechen, ohne negative Folgen befürchten zu müssen. Gerade in regulierten Finanzprozessen ist dieses Verhalten ein Bestandteil wirksamer Risikokontrolle.[10]

Die Kernfrage: Wer denkt hier eigentlich?

Die KI-Transformation verschärft eine klassische Führungsfrage: Sind Mitarbeitende gewohnt, Probleme eigenständig zu strukturieren, Vorschläge zu entwickeln und Entscheidungen vorzubereiten? Oder haben sie gelernt, auf Vorgaben zu warten?

Skalierbare KI-Nutzung entsteht selten ausschließlich im zentralen Transformationsteam oder Centers of Excellence im Headquarter. Relevante Use Cases liegen in den täglichen Reibungsverlusten der Fachbereiche: in Medienbrüchen, wiederkehrenden Prüfhandlungen, unstrukturierten Dokumenten, langen Abstimmungen oder Wissenssilos. Wer diese Potenziale erkennen und weiterentwickeln soll, muss den Status quo hinterfragen dürfen. Dazu gehören kritisches Denken, fachliches Urteilsvermögen und die Bereitschaft, einen ersten Lösungsweg zu testen.

Mikromanagement trainiert das Gegenteil. Es verlagert Denken und Verantwortung nach oben. Beschäftigte optimieren ihre Arbeit auf Zustimmung, statt auf das Ergebnis. Eine Studie von Ryan und Cross verbindet Mikromanagement mit Angst, Demotivation, Unzufriedenheit, geringerem Aufwärtsfeedback sowie Einbußen bei Produktivität und Innovation. Die breitere Führungsforschung zeigt spiegelbildlich, dass Empowering-Leadership Leistung und Kreativität fördert und dass Autonomie mit proaktivem Problemlösen zusammenhängt.[11,12,13]

KI wirkt hier wie ein Verstärker der bestehenden Führungskultur. In einer Kultur mit Eigenverantwortung erweitert sie den Möglichkeitsraum für Experimente. In einer Kontrollkultur kann sie Abhängigkeit, Absicherung und Passivität weiter vertiefen. Die zentrale Führungsleistung besteht daher darin, Orientierung zu geben, ohne aber das Denken abzunehmen.

Die fünf Stufen der Delegation

Für die Praxis hilft eine einfache Unterscheidung: Wer bestimmt das Ziel, und wer bestimmt den Weg?
Das Ziel beschreibt den angestrebten Geschäftswert. Dazu gehören Kundennutzen, Qualitätsniveau, Risikorahmen, Kennzahlen, Priorität und zeitlicher Horizont. Oder – vereinfacht ausgedrückt: Was gilt es zu tun und bis wann? Der Weg umfasst die gewählte Methode, Prozessdesign oder auch die Tool-Auswahl. Zielklarheit ist damit nicht gleichzusetzen mit einer kleinteiligen, detaillierten Lösungsvorgabe.

Für viele Aufgaben der KI-Transformation liegt der produktive Bereich auf Stufe 3 oder 4. Stufe 5 setzt hohe Reife auf beiden Seiten, klare Portfoliologik und hohe psychologische Sicherheit voraus. Stufe 1 und 2 ist typischerweise bei neuen Mitarbeitenden (= Onboarding) oder auch akuten Krisen sinnvoll. Wird ein Führungsverhalten auf Stufe 1 oder 2 jedoch zum Normalfall, entsteht eine Organisation, die auf die Antworten der Führungskraft wartet.

Ein Beispiel eines Finanzdienstleisters verdeutlicht den Unterschied. Ziel ist, die Erstellung eines Kreditvotums um 30 Prozent zu beschleunigen, ohne Abstriche bei Qualität, Nachvollziehbarkeit und regulatorischer Dokumentation. Zusätzlich gelten klare Leitplanken: freigegebene Datenquellen, menschliche Letztentscheidung, dokumentierte Prüfpfade und definierte Abbruchkriterien. Auf Stufe 1 bestimmt die Führungskraft außerdem das Tool, die Prompts, die Prüf-

schritte und die Rollen. Auf Stufe 3 entwickeln die Mitarbeitenden aus Fachbereich, IT, Data und Compliance den geeigneten Prozess, testen Varianten und legen zu vereinbarten Zeitpunkten Evidenz vor. Die Führungskraft bleibt verantwortlich, ohne zum Lösungsarchitekten jedes Details zu werden.

Drei Delegationsfallen

Die Stufen mögen plausibel und selbstverständlich erscheinen. In der gelebten Praxis treten beim Delegieren allerdings typische Stolpersteine auf:

Falle 1: Die Strahlkraft der Führungskraft unterschätzen. Als Beschäftigte mit Personalverantwortung haben wir qua Rolle eine Strahlkraft – aber nicht zwingend im positiven Sinne: Äußert die Führungskraft früh einen konkreten Lösungsansatz, wird dieser zum Anker. Eine Aussage wie „Wir brauchen dafür einen Agenten" verengt die Diskussion, bevor Problem, Alternativen und Risiken sauber geklärt sind. Aufgrund von Funktion, Status und Entscheidungsmacht lässt sich dieses Priming praktisch kaum zurückholen. Die bessere Reihenfolge lautet: zuerst Fragen, Optionen und Annahmen einfordern, danach die eigene Sicht ergänzen.

Falle 2: Rückdelegation zulassen. Ein Teammitglied bringt ein Problem mit, die Führungskraft übernimmt den nächsten Schritt und wird zum Engpass. Das bekannte Bild der „Klammer-Affen" beschreibt diese Dynamik.[14] Hilfreich sind Gegenfragen wie: „Welche Optionen sehen Sie?", „Was empfehlen Sie?", oder: „Welche Entscheidung benötigen Sie von mir?". Die Folge: Unterstützung bleibt verfügbar, aber die Verantwortung wandert nicht automatisch nach oben.

Falle 3: Auf der falschen Ebene führen. Zu viel Vorgabe unterfordert kompetente Mitarbeitende und verhindert Ownership. Zu wenig Führung überfordert Menschen, denen Erfahrung, Zugriff oder Sicherheit fehlen. Die passende Stufe hängt von Kompetenz, Risiko, Reversibilität und Neuigkeitsgrad der Aufgabe ab. Delegationsverhalten ist daher im besten Falle keine Frage des persönlichen Führungsstils, sondern eine situative Entscheidung.

Handlungspunkte für Führungskräfte

Aus der Argumentation folgen klare Empfehlungen:

- Ziele und Leitplanken explizit machen. Klären Sie Ergebniskennzahlen, Qualitätsstandards, Datenregeln, Entscheidungsrechte oder auch Human-in-the-Loop-Guidelines.
- Ergebnisse delegieren, nicht Lösungsrezepte. Formulieren Sie das Ziel so, dass das Team einen eigenen Weg entwickeln kann. Erbitten Sie somit Optionen, Annahmen und Evidenz statt bloßer Zustimmung.
- AI Anxiety und Identität bearbeiten. Sprechen Sie konkret über Rollen, Tätigkeitsverschiebungen und Verantwortlichkeiten. Beteiligen Sie Beschäftigte an der Gestaltung und investieren Sie in rollenbezogene KI-Kompetenz.

Orientierung statt Mikromanagement

Das (scheinbar) Paradoxe: KI-Transformation verlangt zugleich mehr Klarheit und mehr Autonomie. Das macht Führung anspruchsvoller. Führungskräfte müssen ein belastbares Zielbild formulieren, priorisieren, Grenzen setzen und Verantwortung einfordern. Gleichzeitig brauchen sie die Disziplin, eine eigene Lösung nicht vorschnell ins System zu geben.

Wer Kontrolle mit Führung verwechselt, produziert Abhängigkeit. Wirksame Führung bedeutet: klare strategische Ziele und offene Lösungswege. So entsteht eine Kultur, in der Mitarbeitende den Status quo kritisch infrage stellen, KI-Use-Cases proaktiv einbringen, Ergebnisse kritisch prüfen und Transformation mitgestalten. Als Beschäftigte mit Personalverantwortung stellen wir uns daher die Frage: „Habe ich die kulturellen Bedingungen geschaffen, unter denen mein Team Potenziale von KI eigenständig erkennen und sinnvoll Wertbeiträge für die Organisation erzeugen kann?

Fußnoten:

1) PwC (2025): AI adoption could boost global GDP by an additional 15 percentage points by 2035. https://www.pwc.com/gx/en/news-room/press-releases/2025/ai-adoption-could-boost-global-gdp-by-an-additional-15-percentage.html.
2) Stanford Institute for Human-Centered Artificial Intelligence (2025): The 2025 AI Index Report, Economy. https://hai.stanford.edu/ai-index/2025-ai-index-report/economy.
3) McKinsey & Company (2025): The state of AI in 2025: Agents, innovation, and transformation. https://www.mckinsey.com/~/media/mckinsey/business%20functions/quantumblack/our%20insights/the%20state%20of%20ai/november%202025/the-state-of-ai-in-2025.pdf.
4) Holmström, J.; Magnusson, J. (2026; online 2025): Navigating the organizational AI journey: The AI transformation framework. Business Horizons, 69(1), 89–100. https://doi.org/10.1016/j.bushor.2025.01.002.
5) Singla, A.; Sukharevsky, A.; Yee, L.; Chui, M.; Hall, B. (2025): The state of AI: How organizations are rewiring to capture value. McKinsey & Company. https://www.mckinsey.com/~/media/mckinsey/business%20functions/quantumblack/our%20insights/the%20state%20of%20ai/2025/the-state-of-ai-how-organizations-are-rewiring-to-capture-value_final.pdf.
6) Bock, T.; von der Oelsnitz, D. (2025): Leadership-competences in the era of artificial intelligence – a structured review. Strategy & Leadership, 53(3), 235–255. https://doi.org/10.1108/SL-09-2024-0100.
7) Kim, J. J. H. et al. (2025): AI Anxiety: a comprehensive analysis of psychological factors and interventions. AI and Ethics, 5, 3993–4009. https://doi.org/10.1007/s43681-025-00686-9.
8) Chuang, Y.-T.; Chiang, H.-L.; Lin, A.-P. (2025): Insights from the Job Demands–Resources Model: AI's dual impact on employees' work and life well-being. International Journal of Information Management, 83, 102887. https://doi.org/10.1016/j.ijinfomgt.2025.102887.
9) Shonhe, L.; Min, Q. (2025): Mitigating AI-induced professional identity threat and fostering adoption in the workplace. AI & Society, 40, 4079–4092. https://doi.org/10.1007/s00146-024-02170-0.
10) Frazier, M. L. et al. (2017): Psychological Safety: A Meta-Analytic Review and Extension. Personnel Psychology, 70(1), 113–165. https://doi.org/10.1111/peps.12183.
11) Ryan, S.; Cross, C. (2024): Micromanagement and its impact on millennial followership styles. Leadership & Organization Development Journal, 45(1), 140–152. https://doi.org/10.1108/LODJ-07-2022-0329.
12) Lee, A.; Willis, S.; Tian, A. W. (2018): Empowering leadership: A meta-analytic examination of incremental contribution, mediation, and moderation. Journal of Organizational Behavior, 39(3), 306–325. https://doi.org/10.1002/job.2220.
13) Parker, S. K.; Williams, H. M.; Turner, N. (2006): Modeling the antecedents of proactive behavior at work. Journal of Applied Psychology, 91(3), 636–652. https://doi.org/10.1037/0021-9010.91.3.636
14) Blanchard, K.; Oncken Jr., W.; Burrows, H. (2022): Der Minuten Manager und der Klammer-Affe. Wie man lernt, sich nicht zuviel aufzuhalsen. Rowohlt E-Book. https://www.rowohlt.de/buch/kenneth-blanchard-william-oncken-jr-der-minuten-manager-und-der-klammer-affe-9783499614392.