


Tacit Knowledge und industrielle KI

Kann Erfahrungswissen Maschinen beigebracht werden?

Klaus Wessing
Vorstand infpro - Institut für Produktionserhaltung
infpro Arbeitspapier

MICHAEL POLANYI EXPLAINS HIS INSIGHT TO THE SELF (1966)



Eine Anlage läuft stabil, solange der erfahrene Instandhalter Dienst hat. Er hört ein Lager, bevor es heißläuft. Er sieht am Materialfluss, ob eine Linie später aus dem Takt geraten wird. Er korrigiert einen Parameter, legt ein Teil beiseite, ruft kurz in die Instandhaltung. Kein Ticket. Kein großes Verfahren. Im Betrieb heißt das Erfahrung.

Für viele Industrieunternehmen entscheidet sich die nächste Stufe der Wettbewerbsfähigkeit an genau dieser Stelle: Weiß der Betrieb noch, wie seine Produktion wirklich funktioniert? Die Antwort liegt seltener in Handbüchern, Prozessbeschreibungen oder Dashboards, als es die digitale Rhetorik nahelegt. Sie steckt in Köpfen, Händen und Routinen erfahrener Mitarbeiter.

Michael Polanyi hat dieses stille Wissen als Tacit Knowledge beschrieben. Sein berühmter Satz lautet: „We can know more than we can tell.“ Menschen wissen mehr, als sie aussprechen können. In der Produktion ist das tägliche Praxis, kein akademischer Zierrat. Ein Instandhalter hört, dass eine Maschine anders läuft. Ein Werkzeugmacher spürt, dass ein Material sich ungewöhnlich verhält. Eine erfahrene Schichtführerin erkennt an kleinen Verzögerungen, dass eine Linie in wenigen Stunden Probleme bekommen wird. Solches Wissen lässt sich nicht einfach in eine Arbeitsanweisung übertragen. Es entsteht aus Wiederholung, Beobachtung, Fehlern, Korrekturen und langer Nähe zum Prozess.

Für Manager wird dieses Erfahrungswissen strategisch, weil es an vielen Stellen still verschwindet. Fachkräfte gehen in Rente, Schichten werden knapper besetzt, Anlagen werden komplexer, Varianten nehmen zu. Gleichzeitig wächst der Druck, Produktion zu digitalisieren, Daten zu erfassen und KI einzusetzen. Viele Unternehmen verfügen inzwischen über Sensoren, MES-Systeme, Qualitätsdaten und OEE-Auswertungen. Bessere Steuerung folgt daraus noch lange nicht. Zwischen Datenerfassung und betrieblicher Steuerungsfähigkeit liegt ein weiter Weg. Manchmal liegt dort auch nur ein Excel-Sheet, das jemand seit Jahren pflegt und das niemand wirklich versteht.

Lean hat dieses Problem früher erkannt als viele Digitalstrategien. Der Gemba Walk beruht auf der einfachen, aber unbequemen Einsicht, dass relevante Produktionswahrheit am Ort der Wertschöpfung sichtbar wird. Wer nur Kennzahlen liest, sieht Abweichungen spät. Wer den Prozess beobachtet, sieht Suchzeiten, improvisierte Lösungen, Materialstaus, unsaubere Standards, nervöse Routinen. Vor allem sieht er die Menschen, die mit diesen Unschärfen jeden Tag umgehen. In ihrem Verhalten steckt häufig der beste Hinweis darauf, wo ein Prozess stabil ist – und wo er nur stabil wirkt.

KI hebt diesen Befund nicht auf. Sie macht ihn schärfer. Eine KI kann Muster erkennen, Bilder auswerten, Vibrationen analysieren, Wartungsrisiken berechnen oder Qualitätsabweichungen früher melden. Das ist industriell relevant. Doch sie lernt nicht aus Erfahrung wie ein Meister, der eine Anlage seit zwanzig Jahren kennt. Sie braucht Daten, Beispiele, Rückmeldungen, Prozessordnung. Erfahrungswissen muss also zuerst sichtbar gemacht werden, bevor es technisch nutzbar wird. Der erfahrene Mitarbeiter sagt: „Das klingt falsch.“ Die KI braucht dazu Frequenzen, Temperaturwerte, Lastprofile, Historien, Fehlerbilder. Erst dann wird aus einem Gefühl ein lernbares Muster.

Für das Management verschiebt sich damit die Arbeit. KI-Projekte in der Produktion dürfen nicht bei der Software beginnen. Sie müssen beim Prozess beginnen. Wo entsteht kritisches Erfahrungswissen? Welche Mitarbeiter halten bestimmte Anlagen faktisch am Laufen? Welche Störungen werden informell gelöst, ohne dass sie je im System auftauchen? Welche Qualitätsentscheidungen beruhen auf Blick, Griff, Geräusch oder Materialgefühl? Solche Fragen sind unbequem, weil sie zeigen, wie viel industrielle Leistungsfähigkeit an Personen hängt. Darum gehören sie an den Anfang.

Robotik und KI können Tacit Knowledge heute teilweise übertragen. Bei der visuellen Qualitätsprüfung erkennt Computer Vision Oberflächenfehler, die früher nur geschulte Prüfer sicher fanden. Predictive Maintenance macht aus Geräuschen, Schwingungen und Temperaturverläufen Frühwarnsignale. Beim Learning by Demonstration führt ein Mensch einen Roboterarm, der Bewegungen, Kräfte und Bahnen lernt. Cobots übernehmen Handgriffe, die früher einzeln programmiert werden mussten. Science-Fiction ist das nicht mehr. Vollautomatische Fabrikintelligenz ebenfalls nicht. Viele Anwendungen funktionieren gut in begrenzten Aufgabenräumen, mit sauberen Daten und klaren Prozessgrenzen. Im rauen Betrieb wird es schwieriger.

Für Deutschland und Japan ist diese Frage besonders wichtig. Beide Länder besitzen starke industrielle Traditionen, alternde Belegschaften und einen hohen Anteil erfahrungsgetriebener Produktionskompetenz. Japan wirkt dabei oft nüchterner. Robotik und KI werden dort weniger als Bühne der Disruption verstanden, stärker als Mittel, knapper werdendes Produktionswissen zu sichern und Abläufe stabil zu halten. Für Deutschland wäre das eine brauchbare Lehre. Der Mittelstand braucht keine KI-Rhetorik, sondern Werkzeuge, die Rüstzeiten senken, Qualität sichern, Anlagenverfügbarkeit erhöhen, Wissen bewahren und Entscheidungen im Betrieb verbessern.

Tacit Knowledge wird so zur Führungsaufgabe. Wer industrielle KI ernst nimmt, muss zuerst klären, welches Wissen im Betrieb überhaupt geschützt, übersetzt und skaliert werden soll. Aus Folien lernt keine Maschine. Der Roboter lernt nicht aus Strategiebegriffen. Die KI lernt aus geordneten Daten, wiederholbaren Prozessen und menschlicher Rückmeldung. Ohne diese Vorarbeit bleibt sie ein teures Instrument mit begrenztem Nutzen.

Die Managementfrage bleibt schlicht: Wo hängt die Leistungsfähigkeit der Produktion noch an stillen Experten – und was geschieht, wenn sie morgen nicht mehr da sind?



"It's not in the manual. It's in the mind."

Teil II – Von der Erfahrung zur Maschine

Die Vorstellung, Maschinen könnten Erfahrungswissen übernehmen, begleitet die Industrie seit Jahrzehnten. Frühe Expertensysteme der achtziger Jahre trugen diesen Anspruch bereits im Namen. Man wollte das Wissen erfahrener Fachleute formal erfassen und technisch reproduzierbar machen. Die Ergebnisse blieben begrenzt. Der Grund lag weniger in schwacher Software als in einer Fehleinschätzung des Problems. Erfahrungswissen lässt sich selten vollständig abfragen. Der erfahrene Mitarbeiter besitzt oft kein Regelbuch im Kopf. Er erkennt Muster.

Hier beginnt die heutige KI-Debatte in der Produktion. Fortschritte bei Sensorik, Datenverarbeitung und Machine Learning verschieben die Frage. Die Maschine soll Erfahrung nicht mehr Satz für Satz erklärt bekommen. Sie soll Zusammenhänge erkennen. Das verändert Technik und Erwartungen.

Ein typisches Beispiel liefert die Instandhaltung. Ein erfahrener Techniker hört, dass ein Lager anders läuft. Früher blieb diese Einschätzung häufig persönliches Wissen. Heute lassen sich Schwingungen, Temperaturen und Frequenzmuster erfassen und mit historischen Ausfällen vergleichen. Predictive Maintenance arbeitet genau so. Die KI erhält keine menschliche Intuition. Sie erhält Daten, aus denen sich Wahrscheinlichkeiten bilden lassen. Der Unterschied zählt. Der Mensch hört eine Abweichung. Die KI erkennt ein Muster, das statistisch häufig vor einem Schaden auftritt.

Das funktioniert in vielen Anwendungen inzwischen erstaunlich gut. Qualitätsprüfung gehört dazu. In der Fertigung mussten Oberflächen, Schweißnähte oder Materialfehler lange von erfahrenen Prüfern bewertet werden. Computer Vision kann solche Aufgaben heute teilweise übernehmen oder absichern. Kamerasysteme erkennen Kratzer, Formabweichungen oder Mikrorisse mit hoher Präzision, vorausgesetzt die Bildqualität stimmt und der Prozess liefert ausreichend Vergleichsdaten. Industrieunternehmen setzen solche Systeme zunehmend ein, weil Qualitätskontrolle nicht nur Genauigkeit verlangt, sondern auch Wiederholbarkeit und Geschwindigkeit.

Die Grenze zeigt sich dort, wo Erfahrung stark vom Zusammenhang lebt. Ein erfahrener Werkzeugmacher beurteilt ein Teil selten isoliert. Er kennt Materialchargen, Maschinenzustand, Werkzeughistorie und Produktionsdruck. Sein Urteil entsteht im Zusammenhang des Betriebs. Diese Kontextnähe bleibt für KI schwierig. Daten erklären selten von selbst, warum eine Entscheidung getroffen wurde.

Deshalb richtet sich die Aufmerksamkeit der Forschung zunehmend auf Verfahren, die menschliche Erfahrung direkter aufnehmen sollen. Learning by Demonstration gehört zu diesen Ansätzen. Ein Roboter wird dabei nicht vollständig programmiert, sondern beobachtet eine Handlung oder wird geführt. Der Mensch zeigt einen Bewegungsablauf; Sensoren erfassen Kraft, Geschwindigkeit und Bahn. Der Roboter reproduziert anschließend das Gelernte. Besonders bei Montage, Polieren oder Greifvorgängen entstehen dadurch neue Möglichkeiten.


Die Idee wirkt einfach. Die Umsetzung ist hart. Produktionsumgebungen verändern sich. Teile liegen anders, Materialien reagieren unterschiedlich, Toleranzen schwanken. Menschen gleichen solche Abweichungen meist beiläufig aus. Sie korrigieren unbewusst. Für Roboter bedeutet dieselbe Abweichung oft ein neues Problem. Forschung und Industrie arbeiten deshalb mit multimodalen Systemen, die Bilddaten, Kraftsensoren, Sprache und Bewegungsinformationen verbinden. Der Fortschritt ist sichtbar. Vollständige Generalisierung bleibt schwierig .

Große Aufmerksamkeit erhalten derzeit sogenannte Foundation Models für Robotik und Embodied AI. Dahinter steht die Hoffnung, Maschinen könnten ähnlich wie große Sprachmodelle aus riesigen Datenmengen allgemeine Fähigkeiten ableiten. Der Gedanke fasziniert Investoren und Forschungseinrichtungen. Der Betrieb bleibt nüchterner. Solche Systeme zeigen beeindruckende Demonstrationen, kämpfen im Betrieb aber häufig mit Robustheit, Datenerhebung und Übertragbarkeit . Ein Laborversuch ist noch kein stabiler Drei-Schicht-Betrieb.

Für Manager liegt genau dort die praktische Frage. KI und Robotik entwickeln sich schnell. Viele Anwendungen schaffen bereits messbaren Nutzen. Gleichzeitig erzeugt die öffentliche Debatte Erwartungen, die industrielle Umsetzung häufig nicht einlösen kann. Pilotprojekte entstehen rasch. Belastbare Produktionssysteme entstehen langsamer.

Der Mittelstand kennt dieses Spannungsfeld gut. Ein neues KI-System überzeugt in der Präsentation. Im Betrieb entscheidet sich der Nutzen an anderen Größen: Datenqualität, Prozessstabilität, Schnittstellen, Mitarbeiterwissen und Wartungsfähigkeit. Manche Projekte scheitern nicht an der KI, sondern an unklaren Prozessen oder fehlender Datenordnung. Die Technik legt dann lediglich offen, was vorher schon ungeordnet war.

An dieser Stelle berührt die Debatte den Ursprung des Tacit Knowledge. Erfahrungswissen verschwindet nicht, sobald Sensorik und KI verfügbar sind. Häufig wird es sogar sichtbarer. Unternehmen entdecken plötzlich, wie stark ihre Fertigung von informellen Routinen, erfahrenen Mitarbeitern und stillen Korrekturen lebt. Das irritiert. Es schafft zugleich Klarheit.



“We can know more than we can tell.”

Japan verfolgt diesen Weg seit Jahren mit bemerkenswerter Konsequenz. Robotik dient dort häufig dazu, Produktionswissen zu stabilisieren und Fachkräfte zu entlasten. Die demographische Lage zwingt zu pragmatischen Lösungen. KI erscheint deshalb vielerorts als Werkzeug zur Sicherung industrieller Leistungsfähigkeit, weniger als Bühne technischer Selbstüberschätzung. Dieser Blick lohnt sich.

Deutschland steht vor einer ähnlichen Herausforderung. Produktionswissen altert, Fachkräfte fehlen, Varianten nehmen zu und Investitionsentscheidungen geraten unter Druck. Die Diskussion über industrielle KI sollte daher eine einfache Reihenfolge beachten: erst Prozessverständnis, dann Datenordnung, dann KI. Wer diese Reihenfolge dreht, bekommt häufig Stückwerk.

Die entscheidende Frage lautet deshalb nicht, ob Maschinen irgendwann Erfahrungswissen besitzen wie Menschen. Wichtiger ist, ob Unternehmen ihr eigenes Produktionswissen rechtzeitig erkennen, sichern und in steuerbare Abläufe übersetzen. Darin liegt die industrielle Aufgabe. Teil III wird zeigen, welche Rolle Japan, Demographie und New Lean dabei spielen – und warum die Sicherung von Produktionswissen zunehmend zur Standortfrage wird.

Teil III – Japan, Demographie und New Lean

Die Diskussion über Tacit Knowledge führt früher oder später nach Japan. Kulturelle Romantik erklärt daran wenig. Entscheidend ist die industrielle Lage. Japan verbindet seit Jahren drei Entwicklungen, die für Deutschland ebenfalls näher rücken: alternde Belegschaften, knapper werdende Fachkräfte und einen hartnäckigen Anspruch an Qualität, Lieferfähigkeit und Prozessdisziplin. Dazu kommt eine lange Robotikpraxis. Wer verstehen will, weshalb Erfahrungswissen plötzlich strategisch wird, findet dort kein Vorbild zum Nachbeten, aber ein aufschlussreiches Labor der Wirklichkeit.

Japan steht seit Jahren unter dem Druck demographischer Veränderungen. Die Bevölkerung altert, Arbeitskräfte werden knapper, viele Fertigungsbetriebe kämpfen mit Nachfolge und Fachkräftemangel. Für westliche Beobachter klingt das vertraut. Die industrielle Antwort fiel jedoch oft anders aus als in Europa oder den USA. Robotik entstand dort seltener als Ersatzfantasie für menschliche Arbeit. Der Leitgedanke war meist trockener: Produktionsfähigkeit sichern, Qualität stabil halten, Erfahrungswissen länger nutzbar machen.

Das erklärt einen Teil der japanischen Beharrlichkeit beim Thema Automatisierung. Ein Roboter ersetzt dort nicht einfach einen Menschen. Er stabilisiert einen Ablauf. Diese Denkweise wirkt unspektakulär, besitzt aber beträchtliche Folgen für Investitionsentscheidungen und Produktionsstrategie. Ein Betrieb automatisiert dann nicht, weil die Folie moderner aussieht. Er automatisiert, weil eine Linie sonst zu abhängig von wenigen erfahrenen Leuten bleibt.

Toyota zeigt diese Logik besonders klar. Das Toyota Production System beruht seit Jahrzehnten auf der Einsicht, dass Produktionswissen sichtbar werden muss, bevor es verbessert oder übertragen werden kann. Standard Work, Gemba und Kaizen sind deshalb keine Folklore des Lean-Managements. Sie zwingen den Betrieb, Handgriffe, Reihenfolgen, Abweichungen und Verbesserungen genau anzusehen. Ein Werkzeugwechsel bleibt nicht dauerhaft die Kunst eines einzelnen Einrichters. Er wird beobachtet, beschrieben, trainiert und immer wieder korrigiert. Tacit Knowledge verschwindet dadurch nicht. Es bekommt eine Form, mit der ein Unternehmen arbeiten kann.

Für industrielle KI ist das wichtig. Wer Erfahrung technisch nutzbar machen will, braucht vorher genau diese Übersetzungsarbeit. Der erfahrene Mitarbeiter sieht, hört oder spürt eine Abweichung. Das Unternehmen muss klären, woran er sie erkennt. Erst dann lassen sich Sensorik, Bilddaten, Bewegungsdaten oder Wartungshistorien sinnvoll einsetzen.

Toyota ist dafür weniger wegen einzelner KI-Anwendungen interessant, sondern wegen der Produktionsdisziplin, auf der spätere Digitalisierung aufsetzen kann.

FANUC steht für einen anderen Teil derselben Geschichte. Das Unternehmen wird meist als Robotikhersteller wahrgenommen. Für Tacit Knowledge ist interessanter, welche Art von Erfahrung Robotik in stabile Abläufe überführen kann: Handling, Schweißen, Bearbeitung, wiederkehrende Bewegungen, maschinennahe Routinen . Ein erfahrener Schweißer besitzt Gefühl für Bahnführung, Geschwindigkeit und Materialreaktion. Der Roboter bildet nicht dessen gesamte Erfahrung nach. Er übernimmt reproduzierbare Ausschnitte davon. Genau darin liegt der industrielle Nutzen: weniger Streuung, höhere Wiederholbarkeit, geringere Abhängigkeit von knappen Spezialisten.

Omron zeigt die zweite Seite: Sensorik, Vision-Systeme und Qualitätsregelung . In der Qualitätsprüfung wird Tacit Knowledge besonders greifbar. Der erfahrene Prüfer erkennt minimale Abweichungen, weil sein Blick geschult ist. Ein digitales System versucht, diesen Blick technisch zu fassen: Kamera, Beleuchtung, Fehlerklassen, Entscheidungsschwellen, Rückmeldung aus dem Prozess. Das ersetzt das Qualitätsurteil nicht vollständig. Es macht Teile davon wiederholbar und breiter verfügbar. Die Kamera sieht. Die Qualitätsregel entscheidet. Dieser Unterschied bleibt erheblich.

Auch Denso passt in diese Reihe. Der Zulieferer steht beispielhaft für eine Industrie, die Automatisierung, Assistenzsysteme und Wissenssicherung unter dem Druck alternder Belegschaften zusammen denken muss . Wenn erfahrene Mitarbeiter ausscheiden, verschwindet nicht nur Arbeitszeit. Es verschwindet oft Wissen über Montagefolgen, Grenzfälle, Maschinenverhalten und Qualitätsrisiken. Automatisierung wird dann nicht als glänzende Zukunftsgeste interessant, sondern als Schutz gegen Wissensverlust.

Der Unterschied wird sichtbar, sobald man KI-Projekte in der Praxis betrachtet. Viele westliche Debatten kreisen um Disruption, autonome Systeme oder die Vision menschenleerer Fabriken. Der industrielle Alltag folgt meist einer anderen Prüfung. Unternehmen kämpfen mit Lieferfähigkeit, Rüstzeiten, Ausschuss, Energie, Qualität und Personalmangel. Wer eine Fertigung verantwortet, fragt selten nach technologischer Eleganz. Er fragt, ob der Betrieb am Montag stabil läuft.

New Lean gewinnt genau an diesem Punkt Bedeutung. Der Begriff klingt modisch; er wird auch so verwendet. Brauchbar bleibt sein harter Kern. Klassisches Lean zielte auf stabile Prozesse, weniger Verschwendung und kontinuierliche Verbesserung. New Lean ergänzt

diese Arbeit um Daten, Sensorik und KI. Lean wird dadurch nicht abgelöst. Es wird schärfer, wenn die digitale Ebene den Prozess besser sichtbar macht.

Ein Gemba Walk zeigt Verschwendung. Sensoren zeigen ihre Häufigkeit. KI kann Muster erkennen, Prioritäten unterstützen oder Störungen früher sichtbar machen. Der Nutzen entsteht jedoch nur, wenn Prozessdisziplin und Datenqualität stimmen. Viele Unternehmen unterschätzen genau diesen Zusammenhang.

Die Ernüchterung kommt oft schnell. Produktionsdaten liegen verteilt vor, Stammdaten sind unvollständig, Schnittstellen widersprüchlich, Maschinenparks heterogen. Manche Werke besitzen moderne Dashboards und zugleich eine erstaunlich improvisierte Datenpflege. Dann produzieren KI-Systeme Auswertungen, während der Betrieb weiter über Erfahrung und informelle Abstimmung gesteuert wird. Die Technik existiert. Steuerungsfähigkeit entsteht daraus noch nicht.

Japan begegnet diesem Problem häufig mit größerer Geduld. Digitalisierung wird dort vielerorts als Verlängerung industrieller Praxis verstanden, nicht als Parallelwelt zur Produktion. Diese Haltung erklärt, weshalb Robotik und KI in japanischen Unternehmen oft enger mit Qualitätsregeln, Produktionsroutine und Erfahrungswissen verbunden bleiben. Das wirkt langsamer als manche Start-up-Erzählung. Im Betrieb kann Langsamkeit ein Vorteil sein.

Deutschland steht vor einem ähnlichen Weg, allerdings unter anderen Rahmenbedingungen. Der industrielle Kern bleibt stark, gerät aber unter Druck. Energiepreise, Regulierung, Fachkräfte und Investitionszurückhaltung belasten viele Unternehmen. Gleichzeitig wächst der politische und mediale Erwartungsdruck, KI müsse rasch Produktivitätssprünge liefern. Solche Erwartungen bergen Risiken, wenn sie die Vorarbeit überspringen.

Industrie lernt selten im Sprung. Sie lernt über Wiederholung, Anpassung und belastbare Routinen. Gerade der Mittelstand weiß das. Eine neue Maschine verändert keinen Betrieb automatisch. Software ebenfalls nicht. Produktivität entsteht erst, wenn Abläufe klarer, Entscheidungen schneller und Qualität verlässlicher werden.

Darum besitzt Tacit Knowledge eine wirtschaftspolitische Seite. Produktionswissen entscheidet zunehmend über Wettbewerbsfähigkeit. Länder verlieren industrielle Stärke selten in einem einzigen Bruch. Häufig beginnt der Prozess schleichend: Fertigungstiefe sinkt, erfahrene Fachkräfte fehlen, Investitionen werden verschoben, Produktionswissen

wandert ab. Irgendwann entsteht Abhängigkeit. Später fällt auf, dass Steuerungsfähigkeit verloren ging.

Die Diskussion über KI sollte diesen Zusammenhang ernster nehmen. Der Nutzen künstlicher Intelligenz bemisst sich im Industriekontext nicht an der Raffinesse des Algorithmus. Entscheidend bleibt, ob sie Qualität verbessert, Ausfallrisiken senkt, Produktionswissen bewahrt oder Entscheidungen belastbarer macht. Wo diese Wirkung ausbleibt, bleibt KI Demonstration.

Für Manager entsteht daraus eine unbequeme, aber klare Aufgabe. Sie müssen wissen, wo in ihrem Unternehmen kritisches Erfahrungswissen sitzt, wie abhängig Prozesse von einzelnen Personen sind und welche Teile dieses Wissens sich technisch sichern lassen. Diese Arbeit beginnt nicht im Rechenzentrum. Sie beginnt im Prozess.

Teil IV – Was Maschinen lernen können – und was vorerst menschlich bleibt

Die Debatte über KI und Erfahrungswissen neigt zu Übertreibungen. Auf der einen Seite stehen Erwartungen, die Maschinen bereits als universelle Ersatzintelligenz behandeln. Auf der anderen Seite findet sich ein romantischer Reflex, der menschliche Erfahrung grundsätzlich für unersetzlich erklärt. Beides hilft wenig. Der Betrieb liegt dazwischen.

Michael Polanyi hat das Problem früh beschrieben. In *The Tacit Dimension* schrieb er einen Satz, der bis heute erstaunlich präzise wirkt:

„We can know more than we can tell.“

Polanyi meinte damit kein Geheimwissen und keine mystische Intuition. Gemeint war eine schlichte Beobachtung: Menschen handeln oft kompetent, ohne ihre Kompetenz vollständig erklären zu können. Wer Fahrrad fährt, schweißt oder eine Maschine beurteilt, arbeitet mit Wahrnehmung und Erfahrung, die sich nur teilweise sprachlich zerlegen lassen. Daraus entstand später das, was Ökonomen und Arbeitsforscher als Polanyi-Paradox beschrieben haben: Menschen beherrschen zahlreiche Tätigkeiten intuitiv, ohne die Regeln dahinter vollständig verbalisieren zu können.

Genau dort stößt klassische Automatisierung an Grenzen. Ein Roboter lässt sich hervorragend programmieren, solange der Ablauf klar definiert bleibt. Schwieriger wird es bei Unsicherheit, Materialschwankungen oder Situationen, die Erfahrung verlangen.

Ein Beispiel aus der Qualitätsprüfung zeigt das recht deutlich. In der Automobilfertigung mussten Oberflächenfehler lange von erfahrenen Prüfern erkannt werden. Kleine Kratzer, Reflexionsunterschiede oder minimale Lackfehler entziehen sich einfachen Regeln. Heute übernehmen Vision-Systeme einen Teil dieser Arbeit. Kameras und KI erkennen Abweichungen mit hoher Präzision – häufig zuverlässiger als Menschen bei monotonen Prüfroutinen. Der Fortschritt ist real.



“We can know more than we can tell.”

Trotzdem bleibt Erfahrung im Spiel. Ein erfahrener Qualitätsingenieur beurteilt ein Fehlerbild selten isoliert. Er kennt Werkzeughistorie, Materialcharge, Temperaturverlauf und Produktionsdruck. Sein Urteil entsteht aus Zusammenhang. KI erkennt dagegen zunächst Muster in Daten.

Diese Differenz erklärt, warum viele Industrieprojekte zweistufig arbeiten. Der Mensch liefert Erfahrung und Rückmeldung, die KI liefert Geschwindigkeit und Mustererkennung. In der Instandhaltung ist dieses Zusammenspiel besonders sichtbar. Der Techniker hört eine Veränderung im Laufgeräusch. Die KI analysiert Schwingungen, Temperaturen und Historien. Erst zusammen entsteht ein belastbares Bild.

Taiichi Ohno, einer der Väter des Toyota Production System, formulierte das Problem mit bemerkenswerter Trockenheit. Zahlen seien wichtig, sagte er, doch Menschen, die nur auf Zahlen schauen, seien „die schlimmsten von allen“. Ein anderer Satz Ohnos passt

erstaunlich gut zur heutigen KI-Debatte:

„When you are out observing on the gemba, do something to help them.“

Das klingt wie eine Führungsregel für den Shopfloor. Tatsächlich steckt darin ein tieferes Verständnis von Wissen. Beobachtung allein genügt nicht. Wissen entsteht durch Nähe zum Problem.

Die japanische Wissensforschung griff diesen Gedanken später auf. Ikujiro Nonaka und Hirotaka Takeuchi beschrieben Wissen nicht als statischen Besitz, sondern als Bewegung zwischen implizitem und explizitem Wissen – bekannt geworden als SECI-Modell. Tacit Knowledge wird geteilt, teilweise ausgesprochen, dokumentiert, kombiniert und wieder in Erfahrung überführt. Lernen verläuft spiralförmig.

Für die Industrie ist dieser Gedanke erstaunlich praktisch.

Ein erfahrener Einrichter zeigt einem jüngeren Kollegen einen Werkzeugwechsel. Der Jüngere beobachtet, probiert, korrigiert und entwickelt eigenes Gefühl für Material und Maschine. Wissen wandert zunächst von Erfahrung zu Erfahrung. Erst später entstehen daraus Regeln oder Standards.

Die Robotik versucht heute Ähnliches.

Beim Learning by Demonstration wird ein Roboterarm geführt oder beobachtet menschliche Bewegungen. Sensoren erfassen Kraft, Geschwindigkeit und Bewegungsbahnen. Der Roboter lernt nicht über lange Programmzeilen, sondern über Beispiele. Das funktioniert zunehmend gut – beim Greifen, Polieren, Sortieren oder Montieren.

Die Grenze kommt schnell, sobald sich der Kontext verändert.

Ein Mensch merkt meist sofort, wenn ein Bauteil leicht verzogen ist oder Material anders reagiert. Der Roboter benötigt dafür neue Daten oder zusätzliche Trainingschritte. Forschung und Industrie arbeiten deshalb mit multimodalen Ansätzen: Bilddaten, Kraftsensoren, Sprache und Bewegungsmuster werden kombiniert. Fortschritte sind sichtbar. Der vollständig adaptive Universalroboter bleibt vorerst Zukunftsmusik .

Hier hilft Nüchternheit. Große Sprachmodelle und sogenannte Foundation Models wecken derzeit Hoffnungen, Maschinen könnten allgemeine Fähigkeiten ähnlich flexibel lernen wie Menschen. Die Forschung erzielt beachtliche Ergebnisse, kämpft jedoch

weiterhin mit Robustheit, Generalisierung und hohem Datenbedarf. Gerade industrielle Umgebungen stellen harte Anforderungen: Staub, Verschleiß, Varianten, Schichtbetrieb und wechselnde Bedingungen interessieren sich wenig für Laborerfolge.

Für Manager liegt die Konsequenz an anderer Stelle.

Weniger entscheidend ist, ob KI den erfahrenen Mitarbeiter vollständig ersetzt. Entscheidender ist, wie Erfahrungswissen im Unternehmen sichtbar und übertragbar wird. Viele Betriebe entdecken erst im Zuge von KI-Projekten, wie stark ihre Produktion von informellen Routinen lebt. Der Meister, der „das immer richtet“. Die Schichtführerin, die Abweichungen früh erkennt. Der Instandhalter, der eine Anlage faktisch stabil hält.

Solches Wissen ist wertvoll. Und verletzlich.

Nonaka formulierte das einst mit einem Satz, der nüchtern genug klingt, um auch Produktionsleiter nicht zu verschrecken:

„Information is the flow of messages whereas knowledge is created...“

Daten schaffen noch kein Produktionswissen.



“We know more that we can tell.”

Teil V – Managementfolgen: Erst Wissen ordnen, dann KI einführen

Für Manager liegt die Konsequenz weniger in der Technik als in der Reihenfolge. Wer Tacit Knowledge mit KI nutzbar machen will, muss zuerst klären, welches Produktionswissen im eigenen Betrieb überhaupt kritisch ist. Viele Unternehmen beginnen mit Softwareauswahl, Pilotprojekt und Anbieterpräsentation. Das ist bequem, wirkt modern und führt industriell oft falsch los.

Der bessere Anfang liegt näher am Prozess. Welche Anlage läuft nur deshalb stabil, weil ein bestimmter Instandhalter sie kennt? Welche Qualitätsentscheidung trifft eine erfahrene Mitarbeiterin nach Blick, Griff oder Geräusch? Wo werden Störungen gelöst, bevor sie je im System auftauchen? Wo gibt es Excel-Listen, private Notizen, Schichtwissen, Routinen, die niemand dokumentiert hat? Genau dort sitzt häufig das Wissen, das über Lieferfähigkeit, Ausschuss, Rüstzeit und Anlagenverfügbarkeit entscheidet.

Polanyis berühmter Satz – „We can know more than we can tell“ – beschreibt dieses Problem präzise: Menschen verfügen über Können, das sie nur begrenzt aussprechen können. Für die Industrie heißt das: Erfahrungswissen lässt sich nicht einfach abschreiben wie eine Arbeitsanweisung. Es muss beobachtet, begleitet, gemessen, geprüft und in brauchbare Formen übersetzt werden.

Nonaka und Takeuchi haben später gezeigt, wie Unternehmen implizites und explizites Wissen ineinander überführen können. Ihr SECI-Modell beschreibt Wissen nicht als Aktenbestand, sondern als Bewegung: Erfahrung wird geteilt, teilweise ausgesprochen, kombiniert und wieder praktisch eingeübt. Für Produktionsbetriebe ist das kein akademischer Zierrat. Es ist die Grundlage jeder ernsthaften Wissenssicherung.

Daraus entsteht eine einfache Managementregel: KI-Projekte in der Produktion brauchen vorab eine Wissensinventur. Sie ist keine Bürokratieübung. Sie ist Risikoprüfung. Der Betrieb muss wissen, wo einzelne Personen faktisch Produktionsstabilität sichern. Erst danach lässt sich entscheiden, ob Videoanalyse, Sensorik, digitale Arbeitsanweisungen, Predictive Maintenance, Computer Vision oder Robot Learning sinnvoll sind.

Der technische Stand erlaubt bereits einiges. Learning from Demonstration gilt in der Forschung als vielversprechender Weg, um Roboter für industrielle Montage flexibler anzulernen; zugleich betonen aktuelle Arbeiten, dass industrielle Nutzung weiterhin klare Aufgabenräume, saubere Daten und robuste Umgebungen braucht. Predictive Maintenance ist in der Anwendung weiter: Fraunhofer-Projekte arbeiten konkret daran,

heterogene Produktionsdaten mit Machine Learning für vorausschauende Wartung nutzbar zu machen.

Bei Foundation Models und Embodied AI ist die Quellenlage anders. Die Forschung ist lebendig, die Erwartungen sind hoch, doch die belastbare industrielle Reife bleibt begrenzt. Neuere Surveys sprechen ausdrücklich von offenen Problemen bei Generalisierung, Kontrolle, Datenerhebung und Robustheit in dynamischen Umgebungen. Für einen Dreischichtbetrieb ist das keine Fußnote. Das ist die Grenze zwischen Demonstration und Produktion.

Auch Japan sollte man sauber einordnen. Das Land ist robotisch stark, aber nicht mythisch. Laut IFR blieb Japan 2024 der zweitgrößte Markt für Industrieroboter; der operative Bestand lag bei rund 450.500 Robotern, die Neuinstallationen bei 44.500 Einheiten. Das ist eine Zahl, kein Kulturklischee.

Für den Mittelstand folgt daraus ein nüchterner Fahrplan. Erstens: kritisches Erfahrungswissen identifizieren. Zweitens: Prozessdaten und reale Entscheidungen zusammenführen. Drittens: dort digitalisieren, wo dadurch Qualität, Verfügbarkeit, Rüstzeit oder Lieferfähigkeit messbar besser werden. Viertens: KI nicht als Ersatz für Erfahrung behandeln, sondern als Werkzeug, um Erfahrung zu sichern, zu prüfen und breiter verfügbar zu machen.

Die trockene Pointe: Eine schlechte Produktion wird durch KI nicht klug. Sie wird nur schneller sichtbar.

Teil VI - Warum viele KI-Projekte in der Produktion an der Reihenfolge scheitern

Manager sehen bei industrieller KI oft zuerst das Versprechen: weniger Stillstand, bessere Qualität, schnellere Entscheidungen, geringere Abhängigkeit von einzelnen Experten. Das ist verständlich. Die technischen Fortschritte sind real. Zugleich zeigt die aktuelle Quellenlage ein nüchternes Bild: KI verbreitet sich in der Fertigung, aber der Abstand zwischen Anwendung und belastbarer Skalierung bleibt groß. Die OECD weist für die EU aus, dass der Anteil der Unternehmen ab zehn Beschäftigten, die KI nutzen, in der Fertigung zwischen 2021 und 2024 von 7 auf 11 Prozent gestiegen ist. Das ist Wachstum. Es ist auch ein Hinweis darauf, dass industrielle KI noch lange nicht Regelfall ist.

Die breitere Unternehmenswelt wirkt weiter. McKinsey meldete 2025 , dass 88 Prozent der befragten Organisationen KI in mindestens einer Geschäftsfunktion regelmäßig nutzen. Dieselbe Untersuchung betont jedoch, dass viele Unternehmen die Technologie noch nicht skaliert haben. Für die Produktion ist dieser Unterschied entscheidend. Ein Chatbot im Büro lässt sich schneller einführen als ein KI-System, das Ausschuss senkt, Rüstzeiten reduziert oder Anlagenverfügbarkeit verbessert. Dort endet die Präsentationslogik. Der Betrieb beginnt.

In der Fertigung zählen andere Prüfgrößen. Eine KI für Predictive Maintenance braucht saubere Maschinendaten, lange Historien, robuste Sensorik und eine klare Verbindung zwischen Signal und Wartungsentscheidung. Computer Vision braucht stabile Beleuchtung, definierte Prüfmerkmale, trainierte Fehlerbilder und ein Verfahren für Grenzfälle. Ein Roboter, der durch Demonstration lernt, braucht wiederholbare Bewegungen, Toleranzverständnis und sichere Rückmeldung. Das klingt technisch. Es ist Führungsarbeit.

Viele Projekte scheitern, weil sie Wissensarbeit überspringen. Der Betrieb weiß zwar, welche Anlage Probleme macht, aber nicht, welche informellen Eingriffe sie stabil halten. Schichtführer kennen Muster, die in keinem System stehen. Einrichter korrigieren Parameter, ohne daraus eine dokumentierte Regel zu machen. Die Instandhaltung löst Störungen auf Zuruf. Solange erfahrene Mitarbeiter verfügbar sind, funktioniert das erstaunlich gut. Für KI bleibt das ein schwarzes Loch.

Der erste Schritt heißt Klärung, nicht Datenplattform. Wo entstehen die Entscheidungen, die den Betrieb wirklich stabil halten? Welche davon sind dokumentiert? Welche hängen an Personen? Welche lassen sich beobachten, messen, beschreiben oder wenigstens mit Sensordaten verbinden? Erst dann wird aus Tacit Knowledge ein industriell nutzbarer Bestand.

Predictive Maintenance zeigt diesen Weg besonders gut. Neuere Übersichtsarbeiten beschreiben KI-gestützte Wartung als ein Feld mit erheblichem Potenzial zur Senkung von Betriebs- und Wartungskosten; zugleich bleibt der Nutzen abhängig von Datenqualität, Modellpflege und Einbindung in konkrete Wartungsprozesse. Ein Frühwarnsignal ist wertlos, wenn niemand weiß, wer darauf reagiert, welches Ersatzteil bereitliegt und ob die Produktion den Eingriff zulässt.

Ähnlich verhält es sich bei KI-gestützter Qualitätsprüfung. Ein Kamerasystem erkennt Abweichungen. Die industrielle Frage beginnt dann. Was gilt als Fehler? Wer entscheidet Grenzfälle? Wie wird das System nachtrainiert? Was passiert, wenn Material, Beleuchtung oder Lieferant wechseln? Gute Prüfer besitzen oft ein feines Urteil für solche Übergänge. Dieses Urteil muss in die technische Lösung hinein. Sonst ersetzt die KI die Augen. Die Qualitätslogik bleibt draußen.

Der Arbeitsmarkt verstärkt den Druck. Der World Economic Forum Report 2025 beschreibt Qualifikationslücken als eines der größten Hindernisse für Transformation. Für die Fertigung bedeutet das: Unternehmen benötigen nicht nur Data Scientists, sondern Mitarbeiter, die Produktionswissen und Datenarbeit verbinden können. Der beste Algorithmus hilft wenig, wenn niemand im Werk die Sprache der Maschine und die Sprache des Prozesses zugleich spricht.

Damit entsteht eine neue Schlüsselrolle im Betrieb: der Übersetzer zwischen Erfahrung und System. Das kann ein Produktionsingenieur sein, ein Meister mit digitaler Affinität, ein Instandhalter, ein Qualitätsprofi oder ein interdisziplinäres Team. Wichtig ist die Funktion. Jemand muss aus Beobachtungen Datenfragen machen, aus Erfahrungsregeln Prüfregeln, aus Störungen Lernfälle. Diese Arbeit ist unspektakulär. Sie entscheidet über den Nutzen von KI.

Für Manager folgt daraus ein harter Prüfstein. Ein gutes KI-Projekt in der Produktion beginnt mit fünf Fragen: Welches konkrete Problem senkt die Wettbewerbsfähigkeit? Welches Erfahrungswissen ist für die Lösung relevant? Welche Daten bilden dieses Wissen teilweise ab? Wer prüft, ob das Modell im Betrieb richtig liegt? Wie wird das Ergebnis in eine Entscheidung übersetzt? Ohne diese Kette bleibt KI Dekoration.

Die Quellenlage spricht hier eher für Nüchternheit als für Euphorie. AI-Adoption nimmt zu, Robotik und Sensorik werden leistungsfähiger, Foundation Models eröffnen neue Forschungswege. Gleichzeitig bleiben Generalisierung, Robustheit, Datenerhebung und industrielle Skalierung anspruchsvoll. Für Manager ist das keine Bremse, sondern eine Warnung vor der falschen Reihenfolge.

Wer Erfahrungswissen sichern will, muss zuerst die Produktion verstehen. Dann kann KI helfen. Umgekehrt wird es teuer.

Teil VII – Der Fahrplan: Wie Manager Tacit Knowledge in KI-Projekte übersetzen

Wer Tacit Knowledge sichern will, braucht keinen großen Kulturvortrag. Er braucht eine nüchterne Bestandsaufnahme. In vielen Betrieben liegt das kritische Produktionswissen nicht in Systemen, sondern in alltäglichen Eingriffen: ein leicht veränderter Maschinenklang, ein Griff zum richtigen Werkzeug, eine Korrektur am Parameter, eine Entscheidung an der Qualitätsgrenze. Das wirkt klein. Für Lieferfähigkeit und Ausschussquote ist es groß.

Der erste Schritt ist deshalb eine Wissenskarte der Produktion. Manager sollten nicht fragen, welche KI-Anwendung gerade modern wirkt. Sie sollten fragen, wo der Betrieb verwundbar ist. Welche Anlage hat nur zwei echte Kenner? Welche Linie läuft stabil, solange eine bestimmte Schichtbesetzung da ist? Welche Qualitätsentscheidung kann kaum jemand erklären, obwohl alle wissen, wer sie zuverlässig trifft? Solche Punkte gehören heraus aus dem Flurfunk und hinein in eine industrielle Risikoliste.

Tacit Knowledge & Industrielle KI: Erfahrungswissen im digitalen Zeitalter sichern



Danach beginnt die Übersetzung. Erfahrungswissen muss an beobachtbare Vorgänge gebunden werden. Der Instandhalter hört eine Unwucht; das System braucht Schwingungsdaten, Drehzahl, Temperatur, Lastprofil und Historie. Die Prüferin erkennt einen Oberflächenfehler; das System braucht Bilder, Beleuchtung, Fehlerklassen und

Grenzfälle. Der Einrichter spürt, dass ein Werkzeug „zieht“; das System braucht Kraftwerte, Vorschub, Materialcharge und Ausschussverlauf. Aus Erfahrung wird kein Datensatz durch Zauberei. Jemand muss ihn bauen.

Dieser Punkt wird oft unterschätzt. Fraunhofer beschreibt Predictive Maintenance ausdrücklich als schrittweisen Aufbau aus Datenerfassung, Datentransfer und Qualitätsanalyse. Das klingt unspektakulär und trifft den Kern: Vorhersage beginnt mit Datenhandwerk. Ohne saubere Erfassung bleibt auch das beste Modell blind.

Ähnlich verhält es sich bei KI-gestützter Qualitätssicherung. Fraunhofer USA beschreibt Quality 4.0 als Verbindung von Echtzeit-Prozessüberwachung, Datenanalyse, KI, Vernetzung, Edge Computing und Steuerungssystemen. Entscheidend ist dabei der Verbund, nicht die einzelne Software. Eine Kamera besitzt noch keine Qualitätslogik. Erst die Einbettung in Prozess, Prüffregel und Reaktion macht daraus industrielle Steuerung.

Für Robotik gilt dasselbe. Learning from Demonstration wird in neueren Arbeiten als praktikabler Weg beschrieben, industrielle Manipulatoren für flexiblere Aufgaben anzulernen, besonders unter dem Druck von Mass Customization. Die Forschung betont aber auch: Wer solche Verfahren in Fertigungsaufgaben integrieren will, braucht klare Aufgaben, geeignete Demonstrationen und ein methodisches Vorgehen. Der Roboter lernt keine Erfahrung. Er lernt reproduzierbare Ausschnitte daraus.

Damit entsteht ein brauchbarer Managementfahrplan. Erstens: kritisches Erfahrungswissen identifizieren. Zweitens: dieses Wissen an konkrete Prozessereignisse binden. Drittens: die passenden Datenquellen bestimmen. Viertens: Grenzfälle sammeln, weil dort die Erfahrung sitzt. Fünftens: ein System nicht nur trainieren, sondern im Betrieb kontrollieren. Sechstens: Rückmeldungen aus der Fertigung fest einbauen. Ohne Rückmeldung verwaltet KI irgendwann ihre eigenen Irrtümer.

Gerade der letzte Punkt ist heikel. Viele Unternehmen behandeln KI-Modelle wie eingeführte Maschinen. Einmal installiert, sollen sie laufen. Bei Produktions-KI ist das gefährlich. Material wechselt, Lieferanten ändern sich, Anlagen verschleißen, Produktvarianten wachsen. Ein Modell, das gestern gut lag, kann morgen danebenliegen. Industrielle KI braucht Wartung. Technisch. Und fachlich.


Hier kommt der Mensch wieder ins Spiel. Der erfahrene Mitarbeiter verschwindet in diesem Modell nicht. Seine Rolle verändert sich. Er wird zum Prüfer, Lehrer und Korrektiv des Systems. Das ist anspruchsvoller als die alte Gegenüberstellung Mensch gegen

Maschine. Ehrlicher auch. Human-in-the-Loop-Robot-Learning wird in neueren Übersichtsarbeiten gerade deshalb als wichtiges Feld beschrieben: Menschliche Vorkenntnis kann Robotersysteme verbessern, doch die Forschung im industriellen Smart-Manufacturing-Kontext gilt weiterhin als jung und nicht abschließend gelöst.

Für Manager heißt das: KI-Projekte brauchen Verantwortliche, die Prozesswissen und Datenarbeit zusammenbringen. In vielen Werken fehlt diese Rolle noch. Die IT versteht das Modell, die Fertigung versteht den Ablauf, die Qualität versteht die Grenzfälle, die Instandhaltung versteht die Anlage. Der Nutzen entsteht erst, wenn diese vier Wissensbestände nicht nebeneinanderliegen, sondern zusammenarbeiten. Das ist keine Nebensache, sondern Betriebskern.

Die Quellenlage bleibt bei aller Dynamik eindeutig genug für eine vorsichtige Schlussfolgerung. Predictive Maintenance, Computer Vision, Quality 4.0 und Learning from Demonstration sind keine bloßen Zukunftsbilder mehr. Sie haben reale industrielle Anwendungen. Ihre Skalierung hängt aber an Bedingungen, die in vielen Präsentationen zu klein geschrieben werden: Datenqualität, Prozessstabilität, klare Verantwortlichkeit, Rückmeldung aus dem Betrieb und die Fähigkeit, Erfahrungswissen überhaupt zu erkennen.

Ein guter Gemba Walk kann deshalb mehr für KI leisten als manche Strategieklausur. Er zeigt, wo Wissen sitzt. Er zeigt, wo Daten fehlen. Er zeigt, wo Standards tragen und wo Menschen täglich retten, was der Prozess nicht sauber kann. Dort beginnt New Lean. Im Betrieb, nicht im Dashboard.



Teil VIII – Die Grenze: Warum Erfahrung nicht vollständig digital wird

Die Diskussion über industrielle KI gewinnt an Qualität, sobald sie ihre eigenen Grenzen ernst nimmt. Viele Anwendungen funktionieren heute besser, als Skeptiker noch vor wenigen Jahren erwartet hätten. Gleichzeitig bleibt die Vorstellung problematisch, Erfahrungswissen lasse sich vollständig in Daten und Modelle überführen. Die Forschung beschreibt diesen Punkt zunehmend nüchtern.

Robotik und KI lernen gut, wenn Umgebungen strukturiert sind, Aufgaben wiederkehren und ausreichende Daten vorliegen. Schwieriger wird es dort, wo Entscheidungen stark vom Zusammenhang abhängen. Produktion lebt oft genau von solchen Zusammenhängen.

Ein Werkzeugwechsel folgt selten nur einem Handbuch. Der erfahrene Einrichter berücksichtigt Maschinenzustand, Materialcharge, Temperatur, Werkzeugverschleiß, Zeitdruck und Erfahrung mit früheren Störungen. Vieles davon lässt sich erfassen. Nicht alles lässt sich formal beschreiben. Der Unterschied wirkt klein. Er entscheidet viel.

Die Forschung zu Robot Learning und Foundation Models benennt dieses Problem deutlich. Neuere Übersichtsarbeiten sprechen von offenen Herausforderungen bei generalization, also der Übertragbarkeit auf neue Situationen, sowie bei Robustheit und

realer Anpassungsfähigkeit außerhalb kontrollierter Trainingsumgebungen. Ein System lernt eine Aufgabe häufig gut und verliert Sicherheit, sobald der Zusammenhang leicht variiert.

Industrie kennt solche Grenzen seit langem. Ein erfahrener Schweißer oder Instandhalter arbeitet selten nach starrer Regel. Er erkennt Übergänge. Das Material verhält sich anders, die Anlage reagiert ungewohnt, eine kleine Verzögerung kündigt ein größeres Problem an. Oft gibt es dafür keinen einzelnen Messwert. Das Urteil entsteht aus Erfahrung, Vergleich und Lagegefühl.

Gerade deshalb bleibt die Idee einer vollständig menschenleeren Fabrik bislang eher Vision als industrieller Regelfall. Das gilt selbst für hochautomatisierte Produktionsumgebungen. Die International Federation of Robotics beschreibt den globalen Robotikmarkt als dynamisch wachsend; zugleich bleibt Robotik überwiegend in klar definierten Aufgaben stark – etwa bei Handling, Schweißen, Montage oder standardisierten Bewegungsabläufen.

Ein Beispiel macht die Grenze greifbar. Computer Vision erkennt Lackfehler oder Oberflächenabweichungen oft mit hoher Präzision. Das System klassifiziert Muster. Die schwierigeren Fälle beginnen danach. Ist die Abweichung akzeptabel? Handelt es sich um einen funktionalen Fehler oder nur um eine optische Besonderheit? Wie reagiert der Kunde? Muss die Linie gestoppt werden? Solche Entscheidungen enthalten wirtschaftliche und operative Abwägungen. Sie sind mehr als Bildanalyse.

Ähnliches gilt für Predictive Maintenance. Eine KI erkennt steigende Ausfallwahrscheinlichkeiten. Daraus folgt noch keine Wartungsentscheidung. Produktion, Ersatzteilverfügbarkeit, Liefertermin, Schichtplanung und Kosten spielen hinein. Forschung und Praxis unterscheiden deshalb zunehmend zwischen prediction und decision support. Die KI prognostiziert; die Entscheidung bleibt betriebliche Verantwortung.

Manager sollten diese Unterscheidung kennen. Sie schützt vor zwei Irrtümern. Der erste lautet: Erfahrung sei vollständig digitalisierbar. Der zweite lautet: Erfahrung bleibe grundsätzlich untechnisierbar. Beides greift zu kurz.

Tatsächlich entsteht derzeit eine Mischform. KI übernimmt jene Teile von Erfahrungswissen, die beobachtbar, wiederholbar und datenfähig sind. Menschen behalten jene Bereiche, die Urteil, Verantwortung, Kontext und Anpassung verlangen.

Diese Arbeitsteilung klingt weniger spektakulär als manche Zukunftserzählung. Industriell trägt sie weiter.

Die Forschung zur Human-Robot-Collaboration beschreibt diesen Übergang zunehmend als kooperative Architektur. Mensch und Maschine teilen Aufgaben, statt sich vollständig gegenseitig zu ersetzen. Das Ziel lautet, Erfahrung zu stabilisieren und breiter verfügbar zu machen. Gerade Smart-Manufacturing-Konzepte arbeiten deshalb mit human-in-the-loop-Ansätzen, in denen menschliche Rückmeldung Teil des Systems bleibt.

An dieser Stelle berührt die Debatte ihren Ausgangspunkt. Tacit Knowledge war lange unsichtbares Betriebsvermögen. Man wusste, dass es existiert, solange erfahrene Mitarbeiter Probleme lösten. Erst mit KI wird sichtbar, wie abhängig viele Produktionssysteme von diesem stillen Wissen tatsächlich sind.

Das verändert die Führungsaufgabe. Früher genügte es oft, erfahrene Leute zu haben. Heute muss ein Unternehmen zusätzlich verstehen, welches Wissen diese Menschen tragen, wie es entsteht und welche Teile davon gesichert werden können. Wissenssicherung wird damit Teil industrieller Wettbewerbsfähigkeit.

Die nüchterne Schlussfolgerung: KI wird Erfahrungswissen nicht abschaffen. Sie wird dessen Wert sichtbarer machen.

Teil IX – Beispiele: Wo Tacit Knowledge heute bereits maschinenfähig wird

Konkrete Beispiele zeigen besser als jede Grundsatzformel, wo industrielle KI heute steht. Die Lage ist gemischt: nicht armselig, nicht revolutionär. Einige Anwendungen sind im Betrieb angekommen, andere bleiben näher an Forschung und Demonstration. Für Manager ist diese Unterscheidung wichtig, weil sie über Investitionen entscheidet.

Ein erstes Beispiel ist die vorausschauende Instandhaltung. Der klassische Fall ist bekannt: Eine Anlage läuft noch, aber ein erfahrener Instandhalter hört oder spürt, dass sich etwas verändert hat. Früher blieb diese Einschätzung oft personengebunden. Heute lassen sich Schwingungen, Temperaturen, Lastprofile und Betriebszustände erfassen. Fraunhofer EMFT arbeitet in einem aktuellen Projekt daran, auch sehr heterogene Produktionsdaten mit Machine Learning so zu verarbeiten, dass Wartungsbedarf früher erkannt und Stillstand reduziert wird. Der Anspruch lautet „Zero Downtime“; die

industrielle Realität bleibt vorsichtiger. Vorhersage ist nur dann wertvoll, wenn Ersatzteile, Wartungsfenster und Produktionsplanung mitziehen. Ein Warnsignal allein repariert keine Maschine.

Das zweite Beispiel ist Qualitätsprüfung mit Computer Vision. Hier wird besonders gut sichtbar, wie ein Teil von Erfahrungswissen in Daten übersetzt werden kann. Ein Prüfer erkennt Oberflächenfehler, Schraubenfehler oder Montageabweichungen oft schnell, weil sein Blick geschult ist. KI-Systeme versuchen, genau diesen Blick technisch nachzubilden: Kamera, Bilddaten, trainierte Fehlerklassen, Entscheidungsschwellen. Eine 2025 veröffentlichte Fallstudie beschreibt etwa eine YOLOv8-basierte visuelle Prüfung in einer Montagelinie, verbunden mit robotischer Prozesskontrolle. Das beweist nicht allgemein für autonome Qualitätsintelligenz. Es zeigt aber, dass eng umrissene Prüfaufgaben bereits gut automatisierbar sind, wenn Bildqualität, Fehlerdefinition und Prozessumgebung stimmen.

Ein drittes Beispiel betrifft Roboter, die durch Vormachen lernen. Learning from Demonstration ist für die Industrie interessant, weil es den Programmieraufwand senken und Produktionsmitarbeiter stärker einbinden kann. Ein Werker führt einen Roboterarm, das System erfasst Bahn, Kraft, Geschwindigkeit und Greifbewegung. Danach kann der Roboter Teile der Handlung wiederholen. Eine 2024 erschienene Übersichtsarbeit bezeichnet Learning from Demonstration als vielversprechenden Ansatz für industrielle Montage, gerade weil Serienfertigung zunehmend durch Varianten und Mass Customization unter Druck gerät. Der Satz ist wichtig, aber begrenzt: vielversprechend heißt nicht fertig. Übertragbarkeit, Robustheit und wechselnde Umgebungen bleiben anspruchsvoll.

Ein viertes Beispiel liegt in der Qualitäts- und Prozesssteuerung. Fraunhofer USA beschreibt „Quality 4.0“ als Verbindung von Echtzeitüberwachung, Datenanalyse, KI, Edge Computing und Steuerungssystemen. Dahinter steckt ein einfacher industrieller Gedanke: Qualität soll nicht erst am Ende geprüft, sondern im laufenden Prozess geregelt werden. Für Tacit Knowledge ist das relevant, weil erfahrene Mitarbeiter Grenzfälle oft früh erkennen. Ein digitales System muss lernen, diese Grenzfälle zu erfassen, zu klassifizieren und in eine Reaktion zu übersetzen. Die Kamera sieht. Die Qualitätsregel entscheidet. Der Unterschied ist erheblich.

Ein fünftes Beispiel ist Japan. Die Zahlen helfen gegen Folklore. Laut International Federation of Robotics blieb Japan 2024 der zweitgrößte Markt für Industrieroboter;

44.500 neue Einheiten wurden installiert, der operative Bestand stieg auf rund 450.500 Roboter. Das sagt noch nichts über Tacit Knowledge, aber es beschreibt den industriellen Unterbau: Japan verfügt über eine tiefe Robotikpraxis, nicht nur über Debatten über Automatisierung. In Verbindung mit Alterung und Fachkräftemangel wird daraus ein relevantes Experimentierfeld für die Frage, wie Produktionswissen technisch stabilisiert werden kann.

Ein aktueller Blick nach Deutschland zeigt, wie nah Zukunftsversprechen und Industrieprüfung inzwischen beieinanderliegen. Reuters berichtete im Mai 2026, dass Humanoid bis 2032 bis zu 2.000 Roboter an Schaeffler-Standorten einsetzen will; erste Anwendungen sollen ab Ende 2026 in Herzogenaurach und Schweinfurt beginnen, unter anderem für Box Handling und Tests im produktionsnahen Maßstab. Das ist bemerkenswert und verlangt gerade deshalb saubere Einordnung. Es handelt sich um eine geplante Einführung, keine bereits bewiesene Breitenreife. Für Manager ist es trotzdem ein Signal: Robotik rückt näher an Bestandswerke, bestehende Linien und reale Arbeitskräfteknappheit.

Diese Beispiele zeigen ein wiederkehrendes Muster. Tacit Knowledge wird dort maschinenfähig, wo es sich an wiederholbare Vorgänge binden lässt: Schwingung, Bild, Kraft, Bewegung, Temperatur, Fehlerbild, Entscheidungshistorie. Schwieriger bleibt alles, was Urteil, Kontext, Verantwortung und betriebliche Abwägung verlangt. Der erfahrene Mitarbeiter verschwindet daher nicht aus der Produktion. Seine Rolle wandert. Er wird zum Lehrer, Prüfer und Korrektiv technischer Systeme.

Für Manager ergibt sich daraus eine einfache, aber harte Prüffrage: Welche Erfahrung im Unternehmen lässt sich in Daten, Regeln und Rückmeldeschleifen übersetzen – und welche Erfahrung muss bewusst beim Menschen bleiben? Wer diese Grenze kennt, investiert besser. Wer sie ignoriert, kauft Technik und wundert sich später über den Betrieb.

Teil X – Investitionen: Warum KI in der Produktion kein IT-Projekt ist

Wer industrielle KI als IT-Projekt behandelt, hat den Fehler meist schon eingebaut. Die Technik mag aus der IT kommen, der Nutzen entsteht in der Fertigung. Dort entscheidet sich, ob ein Modell Ausschuss senkt, Rüstzeiten verkürzt, Wartung planbarer macht oder Qualitätsentscheidungen verbessert. Der Rest bleibt Demonstration.

Die aktuellen Zahlen stützen eher eine vorsichtige als eine euphorische Sicht. Die OECD weist für die Fertigung in der EU aus, dass der Anteil der Unternehmen ab zehn Beschäftigten, die KI nutzen, von 7 Prozent im Jahr 2021 auf 11 Prozent im Jahr 2024 gestiegen ist. Das ist Fortschritt. Breite industrielle Durchdringung ist es noch nicht. Auch die Konzentration von KI-Kompetenzen bleibt in vielen EU-Ländern im Fertigungssektor niedrig. Für Manager bedeutet das: Wer jetzt investiert, kann Vorteile erzielen; wer Skalierung erwartet, ohne Daten, Prozesse und Kompetenzen aufzubauen, wird enttäuscht.

In der Investitionspraxis wird häufig zu spät gefragt, welches Problem eigentlich gelöst werden soll. Ein Betrieb kauft Sensorik, weil Sensorik modern ist. Er führt Dashboards ein, weil Transparenz gefordert wird. Er testet Computer Vision, weil Qualitätssicherung nach Automatisierung ruft. Solche Vorhaben können sinnvoll sein. Sie werden aber erst tragfähig, wenn sie an eine harte betriebliche Kennzahl gebunden sind: Stillstand, Ausschuss, Nacharbeit, Energieverbrauch, Lieferfähigkeit, Rüstzeit, Prüfaufwand oder Fachkräfteengpass.

Für Tacit Knowledge gilt das besonders. Erfahrungswissen lässt sich nicht pauschal digitalisieren. Unternehmen müssen auswählen. Wo ist der Wissensverlust teuer? Wo droht ein Engpass? Wo hängt ein Prozess an wenigen Personen? Wo kann KI tatsächlich helfen, weil das Wissen in wiederkehrenden Signalen, Bildern, Bewegungen oder Grenzfällen steckt? Erst diese Fragen machen aus Digitalisierung eine Investitionsentscheidung.

Japan liefert hier eine nützliche Vergleichsfolie, sofern man sie nicht romantisiert. Das Land bleibt laut International Federation of Robotics ein Schwergewicht der industriellen Robotik: 2024 wurden 44.500 Industrieroboter installiert, der operative Bestand lag bei rund 450.500 Einheiten. Diese Zahlen belegen keine kulturelle Überlegenheit. Sie zeigen aber, dass Robotik dort in eine breite industrielle Praxis eingebettet ist. Für Deutschland ist das der relevante Punkt: Technik wirkt dort stärker, wo sie auf gewachsene Produktionsdisziplin trifft.

Der Blick auf Deutschland wird durch aktuelle Vorhaben konkreter. Reuters berichtete im Mai 2026, dass Schaeffler bis 2032 zwischen 1.000 und 2.000 humanoide Roboter an Schaeffler-Standorten einsetzen will. Der Einstieg soll Ende 2026 bis Mitte 2027 an den Standorten Herzogenaurach und Schweinfurt erfolgen, zunächst unter anderem für Box Handling und produktionsnahe Tests. Das ist ein wichtiges Signal. Es bleibt eine geplante

Einführung, kein Beweis für sofortige Breitenreife. Genau diese Unterscheidung müssen Manager aushalten.

Investitionen in industrielle KI brauchen daher drei Ebenen. Die erste ist technisch: Sensorik, Dateninfrastruktur, Modelle, Schnittstellen, Cybersecurity. Die zweite ist operativ: stabile Prozesse, klare Verantwortlichkeiten, Rückmeldeschleifen, Wartung des Systems. Die dritte ist wissensbezogen: Welche Erfahrung wird übersetzt, wer prüft die Ergebnisse, wer lernt mit dem System weiter? Viele Projekte decken die erste Ebene ab und unterschätzen die beiden anderen. Dann entstehen teure Inseln.

Der Fachkräftemangel verschärft diese Lage. Der Future of Jobs Report 2025 des World Economic Forum nennt Qualifikationslücken als größten Hemmschuh für Transformation; 63 Prozent der befragten Arbeitgeber sehen sie als zentrale Barriere. Für die Produktion heißt das: KI-Kompetenz allein reicht nicht. Betriebe brauchen Menschen, die Fertigung, Daten und Entscheidung zusammenbringen. Der neue Engpass liegt beim Übersetzen, nicht nur beim Programmieren.

Für den Mittelstand ist das unbequem, aber handhabbar. Er muss nicht jeder KI-Mode folgen. Er muss jene Stellen finden, an denen Erfahrungswissen kritisch ist und technische Unterstützung messbaren Nutzen bringt. Ein Predictive-Maintenance-Projekt an einer Engpassanlage kann wertvoller sein als ein großes KI-Programm ohne Prozessnähe. Eine gute Bilderkennung an einem teuren Qualitätsproblem kann mehr bewirken als ein weiterer Datenraum. Ein sauberer digitaler Standard für Rüstvorgänge kann produktiver sein als ein abstrakter Industrie-4.0-Entwurf.

Die Investitionsregel lautet deshalb: klein genug beginnen, um zu lernen; konkret genug, um Wirkung zu messen; ernst genug, um später zu skalieren. Wer Tacit Knowledge sichern will, braucht keine Bühne. Er braucht einen belastbaren Betriebspfad.

Am Ende entscheidet industrielle KI nicht daran, ob ein Unternehmen modern klingt. Sie entscheidet daran, ob es besser produziert. Das klingt altmodisch. Genau deshalb ist es brauchbar.

Quellen und Literatur

Die folgenden Quellen decken die im Beitrag verwendeten Bezüge, Zahlen und Fachbegriffe ab. Quellenprüfvermerke sind im Text entfernt; der Apparat bündelt die Nachweise am Ende.

1. Michael Polanyi: The Tacit Dimension. University of Chicago Press, 1966/1967. Primärquelle für das Verständnis von Tacit Knowledge und den Satz „We can know more than we can tell“.
<https://search.worldcat.org/title/The-tacit-dimension/oclc/718091>
2. Michael Polanyi: Personal Knowledge. Towards a Post-Critical Philosophy. University of Chicago Press, 1958. Ergänzende Primärquelle zu Wissen, Können und persönlicher Erkenntnis.
3. David H. Autor: Why Are There Still So Many Jobs? The History and Future of Workplace Automation. Journal of Economic Perspectives, 2015. Einordnung des sogenannten Polanyi-Paradoxons und der Grenzen formaler Automatisierung.
4. Ikujiro Nonaka: A Dynamic Theory of Organizational Knowledge Creation. Organization Science, Vol. 5, No. 1, 1994. Grundlage für organisationales Wissen und Wissenstransformation.
5. Ikujiro Nonaka / Hirotaka Takeuchi: The Knowledge-Creating Company. Oxford University Press, 1995. Grundlage für SECI und die Unterscheidung von tacit und explicit knowledge.
https://books.google.com/books/about/The_Knowledge_creating_Company.html?id=B-qxrPaU1-MC
6. ASCN Higher Ed: SECI Model of Knowledge Creation. Überblick zu Socialization, Externalization, Combination und Internalization. https://ascnhighered.org/ASCN/change_theories/collection/seci.html
7. Toyota Motor Corporation: Toyota Production System. Offizielle Darstellung von TPS, Just-in-Time, Jidoka und kontinuierlicher Verbesserung.
<https://global.toyota/en/company/vision-and-philosophy/production-system/index.html>
8. Taiichi Ohno: Toyota Production System: Beyond Large-Scale Production. Productivity Press, engl. Ausgabe 1988. Primärnahe Quelle für TPS, Gemba-Nähe, Fluss, Verschwendung und Produktionsdisziplin.
9. Toyota UK / Toyota: Toyota Production System - glossary. Erläuterungen zu Genba/Gemba, Jidoka und TPS-Begriffen.
<https://mag.toyota.co.uk/toyota-production-system-glossary/>
10. Cabinet Secretariat, Government of Japan: New Robot Strategy. Japan's Robot Strategy - Vision, Strategy, Action Plan, 2015. Japanische Robotikstrategie mit Bezügen zu Fertigung, Mittelstand, Pflege, Infrastruktur und Fachkräftefragen.
https://www.cas.go.jp/jp/seisaku/seicho/pdf/robot_honbun_150210EN.pdf
11. METI / Robot Revolution & Industrial IoT Initiative: Materialien zur New Robot Strategy und zur industriellen Robotikpolitik Japans; Einordnung von Robotik, Society 5.0 und Industriepolitik. <https://www.djw.de/ja/assets/media/Veranstaltungen/Symposium%2C%20MGV/duesseldorf-20180416/djw-symposium-duesseldorf-16.04.2018-kurihara-meti.pdf>
12. International Federation of Robotics: World Robotics 2025 / Global robot demand in factories doubles over 10 years. Japan 2024: 44.500 Neuinstallationen, operativer Bestand 450.500 Roboter.
<https://ifr.org/news/global-robot-demand-in-factories-doubles-over-10-years/>
13. International Federation of Robotics: Best-of World Robotics 2025. Ergänzende Angaben zu Märkten, Installationen und operational stock. <https://ifr.org/worldrobotics/report-2025>
14. OECD: Progress in Implementing the European Union Coordinated Plan on Artificial Intelligence, Volume 2 - AI in manufacturing, 2026. EU-Fertigung: Anteil der Unternehmen ab zehn Beschäftigten mit KI-Nutzung 2021 bis 2024 von 7 auf 11 Prozent. https://www.oecd.org/en/publications/progress-in-implementing-the-european-union-coordinated-plan-on-artificial-intelligence-volume-2_3ac96d41-en/full-report/ai-in-manufacturing_5df4a60d.html

15. OECD: Overview: Progress in Implementing the European Union Coordinated Plan on Artificial Intelligence, 2026. Einordnung der fragmentierten KI-Adoption in der EU-Fertigung. https://www.oecd.org/en/publications/progress-in-implementing-the-european-union-coordinated-plan-on-artificial-intelligence-volume-2_3ac96d41-en/full-report/overview_6ef2d8f8.html
16. World Economic Forum: The Future of Jobs Report 2025. Qualifikationslücken werden von 63 Prozent der Arbeitgeber als zentrales Transformationshindernis genannt. <https://www.weforum.org/press/2025/01/future-of-jobs-report-2025-78-million-new-job-opportunities-by-2030-but-urgent-upskilling-needed-to-prepare-workforces/>
17. McKinsey & Company / QuantumBlack: The State of AI: Global Survey 2025. 88 Prozent der Befragten berichten regelmäßige KI-Nutzung in mindestens einer Geschäftsfunktion; Skalierung bleibt begrenzt. <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>
18. Fraunhofer EMFT: AI-Powered Predictive Maintenance for Manufacturing / Project KIWA. Machine Learning für heterogene Produktionsdaten und vorausschauende Wartung. <https://www.emft.fraunhofer.de/en/projects-fraunhofer-emft/ai-based-predictive-maintenance-manufacturing-equipment.html>
19. Fraunhofer EMFT: Predictive maintenance of gear oils using machine learning / Project Smart Gear. Sensorik und Machine Learning zur kontinuierlichen Überwachung von Getriebeölzuständen. <https://www.emft.fraunhofer.de/en/projects-fraunhofer-emft/machine-learning-predictive-maintenance-gear-oil.html>
20. Fraunhofer USA: Harnessing Quality 4.0 for Predictive and Real-Time Quality, White Paper, 2025. Quality 4.0 als Verbindung von Echtzeit-Prozessüberwachung, Datenanalyse, KI, Connectivity, Edge Computing und Advanced Control Systems. <https://www.fraunhofer.org/content/dam/usa/en/documents/Publications/2025-publications/harnessing-quality-40-for-predictive-and-real-time-quality-march-2025.pdf>
21. Victor H. Moreno / Steffen Jansing / Mikhail Polikarpov / Marc G. Carmichael / Jochen Deuse: Obstacles and opportunities for learning from demonstration in practical industrial assembly: A systematic literature review. Robotics and Computer-Integrated Manufacturing, 2024. DOI: 10.1016/j.rcim.2023.102658.
22. Xuan Xiao u. a.: Robot learning in the era of foundation models: a survey. Neurocomputing, 2025. Überblick zu Foundation Models im Robot Learning, Daten, Simulation, Generalisierung und offenen Forschungsfragen. <https://www.sciencedirect.com/science/article/abs/pii/S0925231225006356>
23. Reuters, 13. Mai 2026: Humanoid to deploy up to 2,000 robots at Schaeffler plants. Geplanter Rollout ab Ende 2026/2027 bis 2032 an Schaeffler-Standorten. <https://www.reuters.com/business/humanoid-deploy-up-2000-robots-schaeffler-plants-2026-05-13/>
24. Reuters, 5. Mai 2026: Schaeffler sees humanoid robotics orders in three-digit million euros by 2030. Einordnung des Schaeffler-Engagements im Robotikmarkt. <https://www.reuters.com/business/schaeffler-sees-humanoid-robotics-orders-three-digit-million-euros-by-2030-2026-05-05/>
25. FANUC: Unternehmensinformationen zu industrieller Robotik, CNC, Fabrikautomation und wiederholgenauer Automatisierung. <https://www.fanuc.co.jp/>
26. OMRON: Unternehmens- und Fachinformationen zu Sensorik, Vision-Systemen, Automatisierung und Qualitätsprüfung. <https://industrial.omron.eu/>
27. DENSO: Unternehmens- und Fachinformationen zu Automatisierung, Robotik, Assistenzsystemen und intelligenter Robotik. <https://www.denso.com/global/en/>