

Nutzung von KI durch Dashboards zur innovativen Steuerung im Controlling – Best Practises für den Strategischen Planungsprozess mit Hilfe von Wertgeneratoren

Bettina Binder

Frank Morelli

Alisa Bay

Florian M.
Rottner

Katharina
M.-T. Schmidt

Hochschule
Pforzheim

Hochschule
Pforzheim

SAP SE

Hochschule
Pforzheim

Hochschule
Pforzheim

Tiefenbronnerstr.
66

Tiefenbronnerstr.
66

Dietmar-Hopp-Allee
16

Tiefenbronnerstr.
66

Tiefenbronnerstr.
66

75175 Pforzheim
bettina.binder@hs-pforzheim.de

75175 Pforzheim
frank.morelli@hs-pforzheim.de

69190 Walldorf
alisa.bay@sap.com

75175 Pforzheim
rottnerf@hs-pforzheim.de

75175 Pforzheim
schmid5t@hs-pforzheim.de

SCHLÜSSELWÖRTER

Dashboard, Wertgeneratoren, Controlling, Künstliche Intelligenz, Power BI, strategische Planung, KPI, Budgetierung

ABSTRACT

Dashboards werden im Controlling bislang vorwiegend zur operativen Steuerung eingesetzt. Dieser Beitrag zeigt, wie ein KI-gestütztes Dashboard auf Basis von Wertgeneratoren den strategischen Planungsprozess innovativ unterstützen kann. Am Beispiel eines international tätigen Fahrrad- und Spielzeugherstellers wird die Entwicklung und Implementierung eines Werttreiberbaums in Microsoft Power BI illustriert. Dabei werden die konzeptionellen Grundlagen zur Auswahl von Spitzenkennzahlen und Wertgeneratoren ebenso erläutert wie die datentechnischen Voraussetzungen einer Business-Intelligence-Architektur. Ergänzend werden KI-Grundlagen, Kernfähigkeiten und Anwendungsmuster – von Prediction über Recommendation bis hin zu Conversational Interfaces – systematisch aufgearbeitet und auf den Controlling-Kontext übertragen. Die praktische Umsetzung zeigt, wie KPI-Visuals, Farbcodierungen und Filterfunktionen in Power BI eine effektive Soll-Ist-Analyse ermöglichen. Das Ergebnis ist ein integriertes, KI-fähiges Dashboard, das als Single Source of Truth quantitative und qualitative Steuerungsinformationen bündelt und Controller bei Analyse, Visualisierung und Entscheidungsunterstützung nachhaltig entlastet.

EINLEITUNG

Dashboards werden heutzutage häufig in der Controlling-Abteilung genutzt, um operative Kennzahlen und deren Entwicklungen der letzten Stunden, Tage oder Wochen darzustellen. In diesem Artikel jedoch erfährt das Dashboard eine erweiterte Einsatzmöglichkeit als Werkzeug zur strategischen Berichterstattung auf Basis von Wertgeneratoren. Eingebettet in ein KI-System werden die KI-Funktionen der Anwendung sowie die Verknüpfung mit dem zugehörigen Controllingprozess näher erläutert.

DER STRATEGISCHE PLANUNGSPROZESS – TRADITIONELL UND DIGITALISIERT

Der strategische Planungsprozess bildet einen zentralen Bestandteil eines Unternehmens und richtet dies langfristig aus. Darüber hinaus werden konkrete Maßnahmen für den operativen Alltag abgeleitet. Eine effektive interne Steuerung entsteht durch die enge Verbindung von Planung, Kontrolle und Informationsmanagement. In diesem System werden strategische Ziele Schritt für Schritt in konkrete Vorgaben umgesetzt, wobei die Budgetplanung eine Schlüsselrolle übernimmt. Sie wandelt geplante Aktivitäten in messbare Key Performance Indicators (KPIs) um und schafft damit die Grundlage für eine zielgerichtete Unternehmenssteuerung (vgl. Horváth et. al. 2024, S. 80 ff.).

Die traditionelle Budgetplanung folgt starren, zyklischen und hierarchischen Prozessen. Dabei werden die langfristigen Ziele in mittelfristige Pläne und festgelegten Budgets differenziert (vgl. Horváth et.al., 2020, S. 94ff.). Sie ist geprägt von langen Planungsphasen, intensiven Abstimmungen zwischen Fachabteilungen und einer starken Orientierung an historischen Daten. Dies führt zu einer Einschränkung der Flexibilität, schafft jedoch Stabilität (vgl. Horváth et. al. 2020, S. 80ff.). Budgets dienen hier als Richtlinie für operative Umsetzung, Zielvereinbarungen sowie ein Vergleich zwischen Soll- und Ist- Zustand zur Überprüfung des Fortschritts (vgl. Horváth et. al., 2024, S. 135ff.; vgl. Britzelmaier, 2020, S. 320ff.).

In der digitalen Welt nutzen Unternehmen bei den strategischen Planungsprozessen IT-gestützte Systeme, um eine effizientere und datengetriebene Budgetierung um-

zusetzen. Darüber hinaus ist eine automatisierte Erfassung von Daten und eine flexiblere Anpassung an neuen Entwicklungen wichtig (vgl. Horváth et.al., 2015, S. 340 ff.). Moderne Ansätze integrieren in ihre Entscheidungen Business Intelligence und Business Analytics zur Analyse großer Datenmengen sowie verbesserte Forecast-Methoden. Dies ermöglicht flexiblere Planung, die über starre Strukturen hinausgeht. (vgl. Horváth et.al. 2015, S. 344ff.)

VORAUSSETZUNGEN UND LÖSUNGSSCHRITTE ZUR EINFÜHRUNG EINES DASHBOARDS MIT WERTGENERATOREN IN POWER BI

Eine zentrale Voraussetzung für die Einführung eines Dashboards mit Wertgeneratoren ist zunächst die Grundkonzeption eines Kennzahlensystems sowie den darin berücksichtigten Wertgeneratoren (vgl. Weber et al., 2017, S. 271). Kennzahlen übermitteln hierbei allgemein quantitative Informationen über das Unternehmen. Sie sind „Maßgrößen, die willentlich stark verdichtet werden zu absoluten oder relativen Zahlen, um mit ihnen in einer konzentrierten Form über einen zahlenmäßig erfassbaren Sachverhalt berichten zu können.“ (Gladen, 2014, S. 9). Folglich ermöglichen Kennzahlensysteme den Fokus des Managements auf wesentliche Informationen zu lenken und damit eine effektive Unternehmensanalyse und -steuerung zu ermöglichen (Vgl. Gladen, 2014, S.9). Die Verhinderung einer Informationsüberflutung ist damit die Grundidee von Kennzahlensystemen und muss bei der Grundkonzeption berücksichtigt werden. Im ersten Schritt erfolgt hierbei die Auswahl der Spitzenkennzahl. Als Auswahlkriterium sollte vor allem die Verständlichkeit dieser für die Entscheidungsträger herangezogen werden und im besten Fall vertraute Steuerungsgrößen wie Bilanz oder Gewinn- und Verlust (GuV) enthalten. In manchen Fällen kann es auch Sinn ergeben, eine zweite Spitzenkennzahl zu definieren, sollte eine nicht alle vom Management gewünschten Sachverhalte abbilden (z.B. zusätzliche Abbildung des Liquiditätsmanagements) (vgl. hierfür auch Reichmann, 2011, S. 36ff.). Um eine effektive Unternehmensanalyse und -steuerung zu gewährleisten, sollte das Kennzahlensystem die Organisationsstruktur des Unternehmens berücksichtigen (z.B. Produktlinien oder Geschäftsregionen). Im dritten Schritt muss ein Rahmenkonzept der Wertgeneratoren definiert werden. Dieses sollte eine funktionale oder sachlogische hierarchische Struktur ergeben und sich bis zur Spitzenkennzahl aggregieren (vgl. Weber et al. S. 271-274). Bei der Auswahl der Wertgeneratoren im Speziellen gilt der Grundsatz: „Weniger ist Mehr“. Eine begrenzte Anzahl von Wertgeneratoren fördert die Verständlichkeit und ermöglicht insbesondere eine effektive Unternehmenssteuerung (vgl. Gladen, 2014, S. 96).

Neben der konzeptionellen gilt es ebenfalls die informationstechnologische Voraussetzung der Datenbereitstellung und -anbindung zu erfüllen. Für das Business Intel-

ligence (BI) gestützte Controlling im Rahmen der Dashboardentwicklung eignen sich transaktionale Systeme, die entlang der Wertschöpfungskette eingesetzt werden, wie bspw. Enterprise-Resource-Planning (ERP)-Systeme oder Customer-Relationship-Management (CRM)-Systeme je nach Werttreiberkonzeption nur selten (vgl. Schön, 2022, S. 467ff.). Besser geeignet als Datenquelle ist ein sog. Data-Warehouse (DWH). Es ist dadurch gekennzeichnet, dass Daten aus verschiedenen transaktionalen Systemen sowie unternehmensexternen Quellen harmonisiert und integriert vorliegen, nach Themenbereichen sortiert, häufig bereits aggregiert sind und Zeiträume betrachtet sowie entgegen der häufig nicht dauerhaften Speicherung von Daten in den transaktionalen Systemen eine Historie abbildet (vgl. Inmon, 2005, S. 29ff. und Baars/Kemper, 2021, S. 20f.). Zudem ermöglichen die im Rahmen der Datentransformation durchgeführte Anreicherung der Daten bereits die Berechnung der für das Kennzahlensystem benötigten Wertgeneratoren sowie der Spitzenkennzahl. Das DWH liefert somit die notwendigen fachlichen entscheidungsunterstützenden Daten, die für die Informationsbereitstellung im Dashboard direkt genutzt werden können (vgl. Baars/Kemper, 2021, S. 35f). Weitere Möglichkeiten wie z.B. Data Lakehouses werden im Kontext dieser Abhandlungen nicht vertieft.

GRUNDLAGEN DER KÜNSTLICHEN INTELLIGENZ

Die ersten Arbeiten zu KI (engl. „Artificial Intelligence“ – AI) entstanden in den 1940er Jahren durch Warren McCulloch und Walter Pitts. Aufbauend auf früheren Überlegungen zum maschinellen „Denken“ entwickelten sie das Konzept künstlicher Neuronen mit binären Zuständen und logischen Verknüpfungen nach dem Vorbild organischer, synaptischen Strukturen. 1950 wurde auf Basis dieser Prinzipien der erste Computer mit einem neuronalen Netzwerk entwickelt (Russell & Norvig, 2021, S. 35). Im selben Jahr stellte Alan Turing die Frage „Can machines think?“ (Russell & Norvig, 2021, S. 20) und schlug den Turing-Test als Operationalisierung dieser Frage vor. Dieser bewertet die Intelligenz einer Maschine anhand ihrer Fähigkeit, menschliches Verhalten so zu imitieren, dass es nicht von dem eines Menschen unterscheidbar ist (Bartneck et al., 2021, S. 9).

Wenige Jahre später wurde der Begriff „Artificial Intelligence“ auf der Dartmouth Conference von John McCarthy et al. geprägt. In ihrem Vorschlag definierten McCarthy et al. KI als die Annahme, dass „every aspect of learning or any other feature of intelligence can in principle be so precisely described that a machine can be made to simulate it“ (McCarthy, 1955, S. 11). Diese These legte den Grundstein für das Forschungsfeld der KI. In den 80er Jahren prägten insbesondere Expertensysteme die KI-Forschung, in denen explizite Wenn-Dann-Regeln mit Hilfe von Inferenzmechanismen implementiert wurden. Ende der 80er bzw. Anfang der 90er

Jahre erfolgte ein Paradigmenwechsel, in dem maschinelles Lernen an Bedeutung gewann. Anstelle der Formulierung von Regeln steht dort algorithmisches Lernen anhand von Beispielen im Vordergrund.

KI lässt sich als interdisziplinäres Forschungsgebiet aus Informatik, Kognitionswissenschaft, Psychologie, Philosophie, Ökonomie und weiteren Disziplinen begreifen. Dabei zeigt es sich, dass der Begriff „Intelligenz“ nur schwer zu definieren ist (Kaplan, 2021, S. 22). Moderne Definitionen orientieren sich primär an agentenbasierten und rationalen Handlungsmodellen. Neben wissenschaftlichen Definitionen gewinnen regulatorische Perspektiven zunehmend an Bedeutung. Die EU definiert im Artificial Intelligence Act ein KI-System als „a machine-based system that is designed to operate with varying levels of autonomy and that may exhibit adaptiveness after deployment [...]“.

Teilbereiche der KI lassen sich u.a. nach Entwicklungsstufen differenzieren (Kaplan und Haenlein, 2019, S. 16 f.):

- Artificial Narrow Intelligence (ANI): Dabei handelt es sich um hochspezialisierte, auf spezifische Aufgaben optimierte KI. Hierzu zählen nahezu alle bestehenden KI-Systeme.
- Artificial General Intelligence (AGI) und
- Artificial Superintelligence (ASI): Diese repräsentieren theoretische Konzepte ohne Relevanz für heutige Unternehmensanwendungen.

Bei Machine Learning (ML) handelt es sich um ein Teilgebiet der KI, das Systeme entwickelt, die aus Daten lernen und sich verbessern (Sarferaz, 2023, S. 374). ML umfasst grundsätzlich drei Lernparadigmen:

- Überwachtes Lernen: Zugehörige Modelle lernen aus gelabelten Daten (Herrmann, 2022, S. 37). Hierunter versteht man Daten, denen ein korrektes Ergebnis (Label) zugeordnet wurde.
- Unüberwachtes Lernen: Es erfolgt eine Mustererkennung in ungelabelten Daten. Zu dieser Kategorie zählt auch das sog. Self-Supervised Learning (Herrmann, 2022, S. 37–43). Dabei lernt ein Modell ohne manuell gelabelte Daten, indem es sich eine Trainingsaufgabe selbst aus den vorhandenen Daten erstellt.
- Reinforcement Learning: Lernen erfolgt in diesem Zusammenhang durch Belohnungsmechanismen. Dieser Lerntyp eignet sich bei Systemen, deren Performance evaluiert werden kann, ohne ihnen die richtige Antwort vorzugeben.

Semi-überwachtes Lernen bezeichnet eine Mischform von überwachtem und unüberwachtem Lernen. Es werden sowohl gelabelte als auch nicht annotierte Datensets verwendet: Zunächst erfolgt ein Training mit annotierten Daten und im Anschluss mit den nicht annotierten Daten, um die Lernperformance zu verbessern.

Deep Learning ist eine ML-Kategorie, bei der sog. tiefe neuronale Netze komplexe Mustererkennungen ermöglichen (Altenfelder et al., 2025, S. 3 f.). Es handelt sich dabei um neuronale Netze, die aus vielen hintereinander geschalteten Schichten (Eingabeschicht, versteckte Schichten und Ausgabeschicht) bestehen. Wichtige Architekturen sind Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs) sowie Transformer-Modelle. CNNs nutzen Faltungen, um lokale Muster zu erkennen und sind spezialisiert auf räumliche Daten, insbesondere Bilder und Dokumente. RNNs besitzen Rückkopplungsschleifen, die Daten aus vorherigen Schritten speichern. Sie sind für sequenzielle Daten konzipiert. Bei Transformer-Modellen handelt es sich um eine moderne Deep-Learning-Architektur, die 2017 eingeführt wurde. Diese nutzen einen Aufmerksamkeitsmechanismus (Self-Attention). Diese Technik erlaubt es, alle Teile einer Sequenz parallel zu betrachten, kontextabhängige Beziehungen zu erkennen und große Modelle zu trainieren. Die Transformer-Architektur basiert auf einer Encoder-Decoder-Struktur, bei der sowohl der Encoder als auch der Decoder aus gestapelten, identischen Schichten bestehen.

Transformer-Modelle bilden die Grundlage für Foundation Models und Large Language Models (LLMs) wie GPT, BERT oder LLaMA. Bei Foundation Models handelt es sich um vortrainierte KI-Modelle, die auf sehr umfangreichen, breit gefächerten Datensätzen trainiert wurden. Sie fungieren als Grundlage für eine Vielzahl spezialisierter Anwendungen. LLMs sind darauf spezialisiert, natürliche Sprache zu verstehen, zu verarbeiten und zu erzeugen. „Large“ steht in diesem Zusammenhang für die Größe des Modells (das oft aus Milliarden von Parametern besteht), der Menge an Trainingsdaten sowie die Breite der beherrschten Aufgaben.

Der Begriff „Conversational AI“ steht für integriertes Sprachverstehen, Generierung und Dialogsteuerung (Sahu et al., 2024, S. 1). Dabei kommt in modernen Systemen auch Retrieval-Augmented Generation (RAG) zum Tragen, um Antworten auf Unternehmensdaten zu stützen und Halluzinationen zu reduzieren. Die Modelle greifen hierbei auf externe Wissensquellen zu, ohne neu trainiert zu werden.

„Agentic AI“ umfasst digitale Systeme, die in der Lage sind, eigenständig zu handeln, zu planen und Ziele zu verfolgen. Sie lassen sich durch folgende Merkmale charakterisieren (Cheng et al. 2024, S. 1 ff; Huang, 2025, S. 2):

- Zielorientiertheit: Die KI ist auf spezifische Ziele ausgerichtet und erstellt mehrstufige Aktionspläne.
- Wahrnehmung: Das System interpretiert seine Umgebung, Daten und Kontext.
- Autonomie: Agenten sind in der Lage, unabhängig zu agieren bzw. selbstständig Aktionen auszuführen und damit ihre Umgebung zu beeinflussen.

- Schlussfolgerung und Selbstüberwachung: Die KI kann Entscheidungen begründen, Ergebnisse überprüfen und Fehler korrigieren.

EIGENSCHAFTEN UND FÄHIGKEITEN KIBASIERTER IT-LÖSUNGEN

Bei der Identifikation und Bewertung von KI-Geschäftspotenzialen gegenüber traditionellen Lösungen lassen sich im Unternehmenskontext verschiedene, untereinander komplementäre Abstraktionsebenen bilden (Bawack et al., 2021, S. 656; Jöhnk et al., 2020, S. 10 f):

(1) Kernfähigkeiten der KI: Hierbei geht es um grundlegende, kognitive Fähigkeiten von KI-Systemen. Im Einzelnen handelt es sich um Wahrnehmung, Verstehen, Handeln und Lernen. In jüngerer Zeit wird auch Generierung als fünfte Kernfähigkeit genannt (Storey et al., 2025, S. 2):

- Wahrnehmen ergibt sich aus der Datenerfassung und -erkennung, beispielsweise aus der Transaktions- und Dokumentenverarbeitung oder aufgrund von Sensordaten.
- Mit Verstehen ist die Interpretation und das semantische Verständnis von Eingaben gemeint. Hierzu gehören z.B. NLP, Kontextanalyse und regelbasierte Schlussfolgerungen.
- Handeln beinhaltet die Ausführung von Aufgaben oder Empfehlungen, beispielsweise im Sinne einer Entscheidungsautomatisierung.
- Lernen ergibt sich aus Leistungsverbesserungen durch Feedback.
- Generieren beinhaltet das Erstellen neuer Inhalte oder Ideen.

(2) KI-Funktionen: Befähigung zur Lösung abstrakter, an menschlicher Kognition angelehnte Aufgaben durch konkrete Aktivitäten. Während die Kernfähigkeiten beschreiben, was ein KI-System grundsätzlich tun kann, erklären KI-Funktionen, wie sich diese Fähigkeiten in geschäftsrelevanten kognitiven Aufgaben manifestieren. Hofmann et al. (2020, S. 10 f.) schlagen sieben KI-Funktionen vor:

- Wahrnehmen: Erfassen und Verarbeiten relevanter Daten,
- Merkmalsextraktion & Identifikation: Erkennen zentraler Merkmale aus Rohdaten,
- Schlussfolgern: Ableiten von Zusammenhängen und Beziehungen,
- Vorhersagen: Prognose zukünftiger Ereignisse oder Ergebnisse,
- Entscheiden: Auswahl optimaler Handlungsoptionen,
- Generieren: Erstellen neuer Artefakte, Inhalte oder Lösungen,
- Handeln: Ausführen von Aufgaben oder Empfehlungen.

Diese Funktionen bilden eine Brücke zwischen abstrakten Fähigkeiten und konkreten Geschäftsapplikationen.

(3) Anwendungsmuster: Standardisierte, wiederkehrende Vorgehensweisen zur Anwendung von KI zur Generierung eines Mehrwerts. Hierdurch sollen Geschäftsziele wie Prozessautomatisierung, Erkenntnisgewinn oder verbesserte Nutzerinteraktion operationalisiert werden (Hassan, 2022, S. 446; Sarferaz, 2024, S. 123 f.). Zu den zentralen Anwendungsmustern gehören:

- Matching: Identifikation von Zusammenhängen zwischen Daten, z. B. Zuordnung von Zahlungen zu offenen Forderungen (Sarferaz, 2024, S. 124).
- Recommendation: Unterstützung von Entscheidungen durch Vorschläge auf Basis historischer Daten (Sarferaz, 2024, S. 125).
- Ranking: Priorisierung, z. B. Sortierung von Forderungen nach Zahlungseingangswahrscheinlichkeit (Sarferaz, 2024, S. 126).
- Prediction: Prognose zukünftiger Ergebnisse (Sarferaz, 2024, S. 126 f.).
- Categorization: Zuordnung von Daten zu vordefinierten Klassen (Sarferaz, 2024, S. 127).
- Conversational Patterns: Natürliche Sprachinteraktion, z. B. Chatbots (Sarferaz, 2024, S. 127 f.).

Die Trennung in verschiedene Abstraktionsebenen ermöglicht eine systematische Zuordnung zu Geschäftsanforderungen, KI-Fähigkeiten und technischen Designelementen.

KI-Anwendungsmuster	KI-Funktionen	Kernfähigkeiten
Prediction	Vorhersagen	Lernen
Recommendation	Schlussfolgern, Entscheiden	Verstehen, Handeln
Categorization	Merkmalsextraktion & Identifikation, Schlussfolgern	Verstehen
Matching	Merkmalsextraktion & Identifikation	Wahrnehmung
Ranking	Schlussfolgern, Entscheiden	Verstehen, Handeln
Conversational Interface	Generieren, Handeln, Wahrnehmen	Generierung, Handeln

Abb. 1: Zuordnung von KI-Anwendungsmustern, Funktionen und Fähigkeiten
Quelle: Bay, A. (2025, S. 16)

Während KI-Fähigkeiten die grundlegenden Bausteine von KI-Systemen beschreiben, liefern KI-Funktionen eine stärker geschäftsorientierte Operationalisierung dieser Fähigkeiten. Sie eignen sich daher besonders, um Nutzerherausforderungen mit potenziellen KI-gestützten Lösungen zu verknüpfen. Im vorliegenden Artikel wird der Schwerpunkt auf KI-Funktionen gelegt:

ANFORDERUNGEN, CHANCEN UND RISIKOPOTENZIALE FÜR DEN KI-EINSATZ

Für die Mensch-Maschine-Kooperation lassen sich je nach Einsatzszenario unterschiedliche Autonomiegrade unterscheiden: In assistierenden Systemen „Human in-the-loop“ (HITL) unterstützt die KI bei Aufgaben, die Menschen grundsätzlich auch selbst ausführen könnten. In erweiterten Systemen („Human-on-the-loop“) bereitet die KI komplexe Entscheidungen vor, die nicht immer vollständig nachvollziehbar sind. In diesem Fall liegt die finale Aufsicht und Kontrolle weiterhin beim Menschen (Dellermann et al., 2021; Schmalzried et al., 2023).

Die Integration von KI in eine bestehende IT-Landschaft bringt technische, organisatorische, ethische und regulatorische Herausforderungen mit sich. Obwohl KI verbesserte Automatisierung, Entscheidungsfindung und Prozessoptimierung verspricht, wird die Realisierung dieser Vorteile häufig durch organisatorische, technische und ethische Hürden behindert (Mhaskey, 2024, S. 4 f.).

Eine grundlegende Voraussetzung ist die Verfügbarkeit hochwertiger, strukturierter Daten. So erzeugen beispielsweise ERP-Systeme große Mengen an Transaktions- und Stammdaten, die die Grundlage für KI-Modelle bilden können. Allerdings beeinträchtigen Dateninkonsistenzen, fragmentierte Systemlandschaften und unzureichende historische Datensätze häufig die Wirksamkeit von KI (Duan et al., 2019, S. 64; Mhaskey, 2024). Aus architektonischer Sicht erhöht die Komplexität moderner IT-Umgebungen die Schwierigkeiten zusätzlich.

Neben diesen technischen Herausforderungen beinhaltet die organisatorische Bereitschaft einen entscheidenden Faktor (Jöhnk et al., 2020, S. 11). Viele Anwender aus den Unternehmensbereichen verfügen nicht über notwendige digitalen Kompetenzen, um KI-Werkzeuge effektiv zu verstehen, anzuwenden und zu bewerten. Dies spiegelt nicht nur einen Mangel an technischen Fähigkeiten wider, sondern auch begrenzte Erfahrung im Umgang mit KI-Systemen. Die Schließung dieser Lücke ist daher nicht nur eine Frage der Schulung, sondern erfordert die Schaffung eines lernorientierten Umfelds.

Weiterhin erweist sich die Nutzerakzeptanz als kritischer Erfolgsfaktor für die Nutzung von KI-Fähigkeiten. Diese hängt zum einen von der wahrgenommenen Nützlichkeit und Benutzerfreundlichkeit von KI-Systemen ab. Zum anderen spielt Vertrauen eine zentrale Rolle. Anwender aus den Fachbereichen benötigen transparente und nachvollziehbare Ausgaben von KI-Systemen (Zebec & Štemberger, 2024, S. 9). Explainable-AI-(XAI)-Techniken können helfen, algorithmische Entscheidungsfindung zu entmystifizieren und menschliche Aufsicht zu unterstützen, was essenziell für das Vertrauen der Nutzer ist (Kaplan & Haenlein, 2019, S. 23; Weber et al., 2023, S. 872 f.). Ferner spielt die adäquate Einbindung in Unternehmensprozesse eine wichtige

Rolle, beispielsweise um bessere Entscheidungen zu unterstützen, ohne die Komplexität zu erhöhen (Sarferaz, 2025, S. 6).

Eng damit verknüpft sind ethischen Aspekte und regulatorischer Compliance-Lösungen (Jöhnk et al., 2020, S. 13). Die Sicherstellung von Fairness, Transparenz und Verantwortlichkeit ist eine Voraussetzung für den langfristigen Vertrauensaufbau in integrierte KI-Funktionalitäten. KI-Empfehlungen müssen beispielsweise frei von Verzerrungen (Bias), nachvollziehbar und korrigierbar sein. Rechtsvorschriften wie die DSGVO (Mhaskey, 2024, S. 4) und der EU-AI-Act (2020, S. 9 f.) setzen strenge Grenzen für Datennutzung und -verarbeitung, insbesondere in sensiblen Bereichen wie Personalwesen und Finanzen. Rechnungslegungsvorschriften verlangen Nachvollziehbarkeit und Prüfbarkeit (Köbler et al., 2022, S. 12). Diese rechtlichen Anforderungen verstärken die Notwendigkeit für KI-Systeme, die nicht nur präzise, sondern auch überprüfbar und erklärbar sind (OECD, 2019, S. 32).

Ferner gilt es aus Unternehmenssicht, die wirtschaftliche und operative Machbarkeit einer KI-Skalierung zu evaluieren (Mhaskey, 2024, S. 4 f.). Während Pilotprojekte häufig vielversprechende Ergebnisse zeigen, erfordert der Übergang in produktive Umgebungen Modell-Retraining und kontinuierliches Monitoring (Jöhnk et al., 2020, S. 12). Der Aufbau nachhaltiger Governance-Strukturen und die Maximierung des langfristigen Return on Investment sind daher ein wichtiger Erfolgsfaktor (Mhaskey, 2024, S. 5).

Um diese multidimensionalen Herausforderungen zu bewältigen, muss ein Unternehmen umfassende KI-Leitprinzipien etablieren, die über die reine Gesetzeskonformität hinausgehen und explizit Fairness, Transparenz, menschliche Aufsicht und Verantwortlichkeit über den gesamten KI-Lebenszyklus hinweg betonen. Gleichzeitig sollte die Komplexität der KI-Integration weniger als Barriere, denn als Katalysator für organisatorische Transformation und Lernen betrachtet werden. Die Diskrepanz zwischen verfügbaren KI-Fähigkeiten und der aktuellen Bereitschaft vieler Unternehmen schafft Raum für die Entwicklung neuer Kompetenzen, Prozesse und Denkweisen. Nach Zebec und Štemberger (2024, S. 17 f.) ist organisatorisches Lernen ein zentraler vermittelnder Faktor, der KI-Adoption in verbesserte Prozess- und Entscheidungsqualität übersetzt und die Bedeutung eines lernorientierten ERP-Umfelds hervorhebt.

EVALUIERUNG EINES PRAXISBEISPIELS

Zur Veranschaulichung der praktischen Anwendung dient das im Folgenden beschriebene Praxisbeispiel. Das betrachtete Unternehmen ist ein international tätiger Hersteller von Fahrrädern, Mountainbikes, Rasenmähern und verschiedenartigen Kinderrädern (z.B. Dreiräder, Kettcars, Tretroller). Die Planung und Budgetierung erfolgten bislang in einem stark zentralisierten, hierarchisch geprägten Top-down-Prozess. Die Fortschreibung der Plan- und Ist-Werte basierte primär auf prozentualen

Anpassungen der Vorjahresdaten. Eine systematische Berücksichtigung von Einflussfaktoren fand dabei keine Berücksichtigung. In Anbetracht der zunehmenden Komplexität des Produktportfolios, einhergehend mit gestiegenen Anforderungen an Transparenz und Steuerungsqualität, wird die Einführung eines harmonisierten Planungs- und Budgetierungssystems verfolgt. Ausgangspunkt dieses Ansatzes ist die Entwicklung und Implementierung eines Werttreiberbaums in Microsoft BI, der die zentralen Key Performance Indicators der Unternehmensleistung strukturiert abbildet und quantitativ in einem Dashboard verknüpft.

LÖSUNGSSCHRITTE ZUR EINFÜHRUNG EINES DASHBOARDS MIT WERTGENERATOREN IN POWER BI

Ist die Grundkonzeption des Kennzahlensystems und die dazugehörige Hierarchie der Werttreiber definiert sowie die Datenanbindung sichergestellt kann mit dem Aufbau des Dashboards begonnen werden (siehe Abb. 2).




Abb. 2: Power BI Visualisierung eines Werttreiberbaums
Quelle: Eigene Darstellung

Die definierte Hierarchie der Wertgeneratoren und Spitzenkennzahl(en) sollte sich auch bei der Visualisierung in Power BI widerspiegeln. Daher sollte die Anordnung der Kennzahlen so gewählt werden, dass daraus hervorgeht, in welcher Beziehung sie zueinanderstehen und wie sie sich beeinflussen. Eine passende Anordnung erleichtert somit einerseits das Verständnis des Kennzahlensystems und andererseits die Analyse sowie Interpretation der Ergebnisse (siehe Abb. 2). In dem hier vorliegenden Fallbeispiel wurde sich für zwei Spitzenkennzahlen entschieden. So werden auf der Ertragsseite einerseits die Wertgeneratoren zur Spitzenkennzahl Economic Value Added (EVA®) aggregiert wohingegen die Liquiditätsseite durch die Cash Conversion Rate (CCR) abgebildet wird. Die Anordnung der darunterliegenden Wertgeneratoren zeigt hierbei, dass bspw. der EVA® aus den Wertgeneratoren Net Operating Profit after Tax (NOPAT) und den Kapitalkosten besteht. Die Kapitalkosten werden wiederum aus dem Gesamtkapital (Hier wird das Gesamtkapital abzgl. der kurzfristige Verbindlichkeiten interpretiert, da diese mit einem kurzfristigen Abfluss an liquiden Mit-

teln führen und somit den Wertgenerator Working Capital und in der Folge das Gesamtkapital mindern) sowie dem gewichteten Kapitalkostensatz (Weight Average Costs of Capital (WACC)) ermittelt, wohingegen das Gesamtkapital aus dem Working Capital und Anlagevermögen (AV) abgeleitet wird. Die unterste Wertgeneratorenebene der Kapitalkosten wird durch das Umlaufvermögen und den kurzfristigen Verbindlichkeiten gebildet. Der zweite Ast der Ertragsspitzenkennzahl EVA® mündet im NOPAT. Dieses ermittelt sich aus den Earnings before Interest and Taxes (EBIT) abzgl. der Steuern. Die Wertgeneratoren des EBIT sind aus dem Gesamt-Deckungsbeitrag (DB), den Sonstigen Erträgen und Aufwendungen sowie dem Finanzertrag definiert. Der Gesamt-DB wird aus der Summe der Produktlinien-DB III abzgl. der Verwaltungskosten (VW-Kosten) bestimmt. Das Kennzahlenmodell spiegelt durch die Trennung des DB III in die Produktlinien die Organisationsstruktur des Unternehmens wider und ermöglicht eine erste Einschätzung der Ertragssituation dieser. Eine weitere Aufgliederung wäre grundsätzlich möglich, führt jedoch zu einer zunehmenden Unübersichtlichkeit des Dashboards. Es empfiehlt sich somit weitergehende Thrill-down Visualisierungen bspw. in Form der Deckungsbeitragsanalyse in einer separaten Visualisierung aufzubereiten. Die Liquiditätsspitzenkennzahl CCR wird als Quotient des Free Cashflow (FCF) und das NOPAT abzgl. Zins berechnet. Der Free Cashflow wird hierbei als Summe der Cashflows aus operativer und Investitionsbedingter Tätigkeit bestimmt.

Für eine effektive Unternehmenssteuerung ist es zudem wichtig, dass das Dashboard einen direkten Vergleich der IST-Werte mit den Plan-Werten ermöglicht bzw. die Plan-Werte mit Zielwerten aus dem strategischen Planungsprozess verglichen werden können. Für eine schnelle Erfassung dieser Abweichungen spielt eine entsprechende Farbgebung (Farbcodierung) eine wichtige Rolle. So sollten Abweichungen, die einen negativen Einfluss auf den entsprechenden Wertgenerator haben rot geschrieben sein, wohingegen Abweichungen mit positivem Einfluss grün dargestellt werden sollten. Die Farbcodierung mithilfe dieser Ampelfarben ermöglicht es den Anwendern Abweichungen schnell zu erkennen und zu interpretieren. Sie lenkt damit den Fokus auf positive und problematische Ausprägungen der Wertgeneratoren, die einer negativen Abweichung einer genaueren Analyse bedürfen. Dies erhöht die Effizienz im Rahmen der Unternehmenssteuerung. Die Farbcodierung vermittelt jedoch lediglich eine nominale Information (Abweichung positiv oder negativ) und nicht die Ausprägung der Abweichungshöhe. Für Anwender des Dashboards kann jedoch diese Information ebenso wichtig sein, um zu erkennen, ob die Zielsetzung nur knapp oder deutlich über- bzw. unterschritten wurde. Die Angabe einer prozentualen Abweichung zum Zielwert kann hierbei zielführend sein und ermöglicht Anwendern eine schnelle und einfache Interpretation der Abweichungshöhe (siehe Abb. 3).

Darüber hinaus können sich Anwender ebenfalls für die Entwicklung der Wertgeneratoren und Spitzenkennzahl(en) im Zeitverlauf interessieren, z.B. wenn die Entwicklung im Rahmen einer mehrjährigen Budgetplanung analysiert werden soll. Ein Liniendiagramm als Trendlinie kann hierbei auf einen Blick darstellen, wie sich die Kennzahlen über die betrachteten Perioden entwickelt hat. Auch hierbei ist die Verwendung einer entsprechenden Farbcodierung mithilfe der Ampelfarben sinnvoll, um die Informationsinterpretation zu vereinfachen (siehe Abb. 2).



Abb. 3: KPI-Visualisierungselement (sog. Visual) in Power BI
Quelle: Eigene Darstellung

Power BI bietet für die obigen Anforderungen das „KPI“-Visualisierungselement (sog. „KPI“-Visual) an. Diese Visualisierung ermöglicht es im ersten Schritt die Kennzahl (Key Performance Indicator (KPI)) festzulegen, die dargestellt werden soll. Darüber hinaus wird die Trendlinie über die betrachteten Perioden im Hintergrund des Visuals visualisiert und entsprechend der Entwicklung mit einer Farbcodierung versehen. Ebenfalls ist die Hinterlegung des Zielwertes möglich (siehe Abb. 4). Das Visual vergleicht dessen Ausprägung automatisch mit dem tatsächlichen Wert und passt daraufhin die Farbcodierung des Visuals an. Die Abweichung mit einem negativen Einfluss auf den Wertgenerator wird zusätzlich zu der roten Ampelfarbe ein rotes Ausrufezeichen angegeben sowie die prozentuale Abweichung berechnet (siehe Abb. 2). Wird ein Zeitraum visualisiert, zeigt das Visual die Werte der letzten Periode an (in Abb. 2 bspw. „Plan 2012“). Über die Formatierung des Visuals kann definiert werden, welche Entwicklung der Trendlinie bzw. Abweichung zum Zielwert als positiv bzw. negativ interpretiert werden soll (siehe Abb. 4 – rechter roter Kasten).




Abb. 4: Spezifikation des KPI-Visuals in Power BI
Quelle: Eigene Darstellung

Für manchen Wertgeneratoren kann es zudem sinnvoll sein auch ihren relativen Wert als Zusatzinformation anzugeben (bspw. EBIT in Prozent vom Umsatz oder Steuerquote). Möchte man dies mit dem „KPI“-Visual umsetzen, müsste zusätzlich zur Visualisierung des absoluten Wertes dieses Wertgenerators ein weiteres Visual kreiert werden. Dies kann jedoch eine Unübersichtlichkeit generieren. Eine andere Möglichkeit ist es diese Information in das bestehende „KPI“-Visual der absoluten Darstellung des Wertgenerators zu integrieren. Hierfür kann ebenfalls das „KPI“-Visual genutzt werden, jedoch wird dieses ohne Zielwert und ohne Trendlinie angegeben, da diese Information bereits mit der Darstellung des absoluten Wertes abgebildet ist. Dies kann erreicht werden, indem das Visual mit transparentem Hintergrund formatiert wird, sodass eine Einpassung in das bestehende Visual des Wertgenerators möglich ist (siehe Abb. 5).




Abb. 5: „KPI“-Visual inklusiver der Darstellung der relativen Ausprägung der Wertgeneratoren
Quelle: Eigene Darstellung

Zuletzt sollte ebenfalls berücksichtigt werden, dass das Dashboard im Rahmen einer „Self-Service“-Nutzung der Anwender auch eine Dynamisierung durch unterschiedliche Auswertmöglichkeiten ermöglicht. Für Kennzahlensysteme ist häufig die Entwicklung über mehrere Perioden für die Anwender von Interesse. Es empfiehlt sich daher ein Filtermenü einzufügen, das den Anwendern eine nutzerspezifische Auswahl der Perioden ermöglicht. So sind die Anwender selbst in der Lage eigene Analysen vorzunehmen und unterschiedliche Perioden und die

dazu gehörigen Entwicklungen zu vergleichen (bspw. Budget- und IST-Werte wie in Abb. 6 dargestellt).




Abb. 6: Filterfunktion zur Analyse der Periode
Budget 2010 und IST-Werte 2010
Quelle: Eigene Darstellung

Wird Power BI im geschäftlichen Umfeld und mit einer Pro- oder Premium-Lizenz genutzt ist zudem das Hinzufügen von Kommentaren zu einem Dashboard möglich (Vgl. Microsoft, URL). Dies kann besonders hilfreich sein, um Abweichungen direkt im Dashboard zu erläutern und dem Management qualitative Hintergründe über die Ausprägung und Entwicklung der Wertgeneratoren und Spitzenkennzahl(en) zu geben. Somit werden alle für die Unternehmenssteuerung wichtigen quantitativen und qualitativen Informationen an einem Ort verfügbar gemacht. Das Dashboard fungiert damit als sog. „Single Source of Truth“.

Eine sinnvolle Weiterentwicklung des Werttreiberbaums stellt die erweiterte Deckungsbeitragsrechnung dar, da sie eine präzisere Analyse der Kosten- und Ergebnisstruktur ermöglicht. Durch die Aufteilung der Kosten in weitere Deckungsbeitragsstufen wird eine systematische Untersuchung von Kostensensitivitäten und eine verbesserte Bewertung der Auswirkungen von Veränderungen in Bezug auf Mengen, Preise oder Kosten erzielt. Dementsprechend können ökonomische Risiken frühzeitig lokalisiert werden und fundierte Entscheidungen hinsichtlich des Produktportfolios, der Marktstrategien sowie der Internationalisierung abgeleitet werden.

HANDLUNGSEMPFEHLUNGEN UND FAZIT

Traditionelle Kenntnisse des Controllers bleiben unverlässlichlich zur Kennzahlenbestimmung und Analyse. Neue Kenntnisse der Einbindung dieser Steuerungskennzahlen operativ und strategisch (vgl. Binder, Morelli 2025, S.52 ff.) mit Hilfe von Wertgeneratoren in ein Power-BI erfordern weitere vertiefte IT-Kenntnisse der Controller. Darüber hinaus ist der Einsatz von Dashboards mit Unterstützung von KI die Entwicklung der Zukunft bei der die Rohdaten (z.B. in Excel) per Texteingabe (Prompt) hochgeladen werden können, so dass automatisiert Diagramme und Key Performance Indicators (KPIs) generiert werden können. Damit übernimmt die KI die Datenanalyse, Layoutgestaltung und Visualisierung, so dass der Controller bei der Erarbeitung eines Dashboards damit hilfreich unterstützt werden kann.

LITERATUR

- Altenfelder, K., Kieffer-Radwan, S., & Schönfeld, D. (2025). Einleitung: Wie die Algorithmen Einzug in das Services Management gehalten haben, Die historische Entwicklung der Künstlichen Intelligenz. In K. Altenfelder, S. Kieffer-Radwan, & D. Schönfeld, Services Management und Künstliche Intelligenz, Grundlagen und Anwendungsfelder für den Einsatz von KI-unterstützten Service (pp. 1-18). Wiesbaden: Springer Nature. doi:<https://doi.org/10.1007/978-3-658-46665-7>
- Bartneck, C., Lütge, C., Wagner, A., & Welsh, S. (2021). An Introduction to Ethics in Robotics and AI. Cham, Switzerland: Springer Nature. doi:<https://doi.org/10.1007/978-3-030-51110-4>
- Bawack, R. E., Wamba, S. F., & Carillo, K. D. (2021). A framework for understanding artificial intelligence research: insights from practice. *Journal of Enterprise Information Management*, 34(2), 645-678
- Bay, Alisa (2025). Artificial Intelligence in Financial Closing: Identifying, Designing, And Demonstrating AI-Driven Use Cases for an Enterprise Software Company, Master's Thesis, University of Ljubljana. School of Economics and Business
- Binder B.C.K., Morelli F. (2025), Digitale Zwillinge zur Optimierung des Budgetierungsprozesses – Dashboards und Process Mining unterstützen ein prozessorientiertes Performance Measurement, in: *Industry 4.0 Science*, Ausg. 2/2025, S. 52 - 58
- Britzelmaier, B. (2020): Controlling. Grundlagen, Praxis, Handlungsfelder, 3. Auflage, Pearson Studium, München
- Cheng, Yuheng; Zhang, Ceyao; Zhang, Zhengwen; Meng, Xiangrui; Hong, Sirui; Li, Wenhao; Wang, Zihao; Wang, Zekai; Yin, Feng; Zhao, Junhua und He, Xiuqiang (2024): Exploring Large Language Model based Intelligent Agents: Def-initions, Methods, and Prospects. *arXiv Preprint arXiv:2401.03428*, URL: <https://arxiv.org/pdf/2401.03428.pdf>, abgerufen am 08.11.2025
- Dellermann, D., Lipusch, N., Ebel, P., & Leimeister, J. M. (2021). CrowdServ –Konzept für ein hybrides Entscheidungsunterstützungssystem zur Validierung von Geschäftsmodellen. In D. Beverungen, J. H. Schumann, V. Stich, & G. Strina (Eds.), *Dienstleistungsinnovationen durch Digitalisierung: Band 2: Prozesse – Transformation – Wertschöpfungsnetzwerke* (pp. 299–331). Springer. https://doi.org/10.1007/978-3-662-63099-0_8
- Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *International Journal of Information Management*, Vol. 48, 63-71.

doi:<https://doi.org/10.1016/j.ijinfomgt.2019.01.021>

- European Union. (2024). Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). Official Journal of the European Union, L 168, 1-159.
- Gladen, W. (2014). Performance Measurement- Controlling mit Kennzahlen. Wiesbaden: Springer Gabler. doi:10.1007/978-3-658-05138-9
- Gleich, R., Gänßlen, S., Kappes, M., Kraus, U., Leyk, J., Tschandl, M. (2015). Moderne Instrumente der Planung und Budgetierung: Innovative Ansätze und Best Practice für die Unternehmenssteuerung. 2. Auflage. Haufe Verlag. München
- Gleich, T., Kappes, M., Leyk, J. (2019). Planung, Budgetierung und Forecasting: Innovative und digitale Instrumente für die Unternehmenssteuerung. 1. Auflage. Haufe Verlag. München
- Hasan, A. R. (2022). Artificial Intelligence (AI) in Accounting & Auditing: A Literature Review. Open Journal of Business and Management. 10, 440-465. doi:<https://doi.org/10.4236/ojbm.2022.101026>
- Herrmann, J. (2022). Künstliche Intelligenz mit den Themenschwerpunkten maschinelles Lernen und künstlichen neuronalen Netzen, dargestellt anhand des Beispiels von Blended-Learning-Übungen. In C. Aichele, & J. Herrmann, Betriebswirtschaftliche KI-Anwendungen, Digitale Geschäftsmodelle auf Basis Künstlicher Intelligenz (2. ed., pp. 17-76). Wiesbaden: Springer. doi:<https://doi.org/10.1007/978-3-658-40099-6>
- Hofmann, P., Jöhnk, J., Protschky, D., & Urbach, N. (2020). Developing purposeful AI use cases - A structured method and its application in project management. 15. International Conference on Wirtschaftsinformatik (WI) 2020. Proceedings. 1, pp. 1-16. Potsdam: GITO Verlag. doi:10.30844/wi_2020_a3-hofmann
- Horváth, P., Gleich, R., Seiter, M. (2024). Controlling. 15. überarbeitete Auflage. München. Vahlen.
- Huang, K. (2025). The Genesis and Evolution of AI Agents. In K. Huang, Agentic AI, Theories and Practices (pp. 1-22). Cham, Switzerland: Springer Nature. doi:<https://doi.org/10.1007/978-3-031-90026-6>
- Inmon, W. H. (2005). Building the Data Warehouse (4. Ausg.). New York: Wiley Computer. Publishing.
- Jöhnk, J., Weißert, M., & Wyrski, K. (2020). Ready or Not, AI Comes - An Interview Study of Organizational AI Readiness Factors. Business & Information Systems Engineering, 63, 5-20
- Kaplan, A. (2021). Artificial Intelligence (AI): When Humans and Machines Might Have. In P. Verdegem, AI for Everyone? Critical Perspectives (pp. 21-32). London: University of Westminster Press. doi:<https://doi.org/10.16997/book55.b>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. Business Horizons, 62(1), 15-25. doi:<https://doi.org/10.1016/j.bushor.2018.08.004>
- Köbler, M., La Kier, H. A., Prabakar, S., & Six, M. (2022). Introducing SAP S/4HANA Cloud for Advanced Financial Closing. Bonn: Rheinwerk Verlag GmbH
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (1955). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. Hanover, New Hampshire: Dartmouth College.
- Mhaskey, S. (2024). Integration of Artificial Intelligence (AI) in Enterprise Resource Planning (ERP) Systems: Opportunities, Challenges, and Implications. International Journal of Computer Engineering in Research Trends, 11(12), 1-9
- Microsoft. (URL). Hinzufügen von Kommentaren zu einem Dashboard oder Bericht. Abgerufen am 15.03.2016 von <https://learn.microsoft.com/de-de/power-bi/explore-reports/end-user-comment>
- OECD. (2019). Artificial Intelligence in Society. Paris: OECD Publishing. doi:<https://doi.org/10.1787/eedfee77-en>
- Reichmann, T. (2011). Controlling mit Kennzahlen - Die systemgestützte Controlling-Konzeption mit Analyse- und Reportingsinstrumenten (8. Ausg.). München: Vahlen.
- Russell, S. J., & Norvig, P. (2021). Artificial Intelligence, A Modern Approach (4. ed.). Harlow: Pearson.
- Sarferaz, S. (2023). ERP-Software: Funktionalität und Konzepte, Basierend auf SAP S/4HANA. Wiesbaden: Springer Nature.
- Sarferaz, S. (2024). Embedding Artificial Intelligence into ERP Software, A Conceptual View on Business AI with Examples from SAP S/4HANA. Cham, Switzerland: Springer Nature. doi:<https://doi.org/10.1007/978-3-031-54249-7>
- Sarferaz, S. (2025). Implementing Generative AI into ERP Software. IEEEAccess, 1-13. doi:10.1109/ACCESS.2025.3564133
- Schmalzried, D., Hurst, M., Wentzien, M., & Gräser, M. (2023). Analyse der Rolle künstlicher Intelligenz für eine menschenzentrierte Industrie 5.0. HMD Praxis der Wirtschaftsinformatik, 60(6), 1143-1155. <https://doi.org/10.1365/s40702-023-01001-y>
- Schön, D. (2022). Planung und Reporting im BI-gestützten Controlling - Grundlagen, Business Intelligence, Mobile BI, Big-Data-Analytics und KI (4 Ausg.). Wiesbaden: Springer Gabler. doi:<https://doi.org/10.1007/978-3-658-35475-6>
- Storey, V., Yue, W., Zhao, J., & Lukyanenko, R. (2025). Generative Artificial Intelligence: Evolving

Technology, Growing Societal Impact, and Opportunities for Information Systems Research. *Information Systems Frontiers*, 1-22. doi:<https://doi.org/10.1007/s10796-025-10581-7>

Weber, J., Bramseman, U., Heineke, C., & Hirsch, B. (2017). Wertorientierte Unternehmensführung - Konzepte-Implementierung-Praxis-Statement (2. Ausg.). Wiesbaden: Springer Gabler. doi:10.1007/978-3-658-15216-1

Zebec, A., & Štemberger, M. (2024). Creating AI business value through BPM capabilities. *Business Process Management Journal*, 30(8), 1-26. doi:10.1108/BPMJ-07-2023-0566

KONTAKT



Bettina C.K. Binder ist Professorin für Controlling, Prozessmanagement und Strategische Unternehmensführung an der Hochschule Pforzheim. Zuvor war sie 14 Jahre in der Managementberatung und als Finance Director tätig.



Frank Morelli ist Professor für Wirtschaftsinformatik an der Hochschule Pforzheim. Er forscht im Bereich Business Intelligence und hat die Hochschule Pforzheim als Celonis Academic Center of Excellence etabliert.



Alisa Bay ist Business Processes Consultant bei der SAP Deutschland SE & Co. KG mit dem Schwerpunkt Finance. Sie absolvierte ein Double-Degree-Masterstudium in Information Systems und Business Informatics an der Hochschule Pforzheim und University of Ljubljana.



Florian Rottner ist Controlling Professional bei der Siemens Energy Global GmbH & Co. KG im Geschäftsbereichcontrolling. Er absolvierte ein Duales Studium mit dem Schwerpunkt BWL-Industrie an der Dualen Hochschule Baden-Württemberg in Karlsruhe. Zurzeit studiert Florian Rottner im Master Controlling, Finance und Accounting an der Hochschule Pforzheim.



Katharina Marie-Therese Schmidt ist Studentin im Masterstudiengang Controlling, Finance & Accounting an der Business School Pforzheim. Ihren Bachelorabschluss erwarb sie 2025 am Campus Künzelsau der Hochschule Heilbronn mit einer Abschlussarbeit zur Implementierung einer Self-Service BI Anwendung im Controlling eines mittelständischen Unternehmens.