

Zwischen Hype und Handlung: Ist Ihr Controlling bereit für KI?

Florian Bliefert

Hashim@Adobe.com



Summary

Trotz hoher Investitionen erzielen 95 % der Unternehmen keinen messbaren KI-Nutzen! Der Grund ist oft die fehlende organisatorischer Einbettung. Ein strukturierter Check entlang vier Dimensionen hilft bei der Umsetzung: Daten & Technologie, Rollen & Organisation, Governance & Compliance sowie Kultur & Veränderungsbereitschaft. Wer die eigenen Lücken kennt und gezielt schließt, legt den Grundstein für erfolgreiches, modernes Controlling.

Die Zahlen sind ernüchternd: Eine MIT-Studie aus dem Jahr 2025 zeigt, dass 95% der Unternehmen trotz milliardenschwerer Investitionen in KI keinen messbaren Return erzielen konnten. Das liegt nicht an schlechten Algorithmen oder fehlender Rechenleistung, sondern an unzureichender organisatorischer Einbettung. Modelle entstehen nicht im luftleeren Raum; sie benötigen saubere Daten, klare Verantwortlichkeiten, transparente Regeln und eine Umgebung, die datengetriebene Entscheidungen wirklich unterstützt.

Viele Führungskräfte und Controller fragen sich daher zu Recht: Sind wir überhaupt bereit für Data Science und KI? Bevor Ressourcen in komplexe Forecast-Modelle oder KI-gestützte Analysen fließen, lohnt sich ein struk-



**Florian
Bliefert**

MBA und B.Sc. ist als Manager bei der CA Akademie AG sowohl als Trainer als auch Berater tätig. Seine Schwerpunkte liegen in den Bereichen Kosten- und Leistungsrechnung, Planung und Reporting. Er betreut seine Kunden bei Projekten in den Bereichen KI, Predictive Analytics, Data Mining und Robot Process Automation (RPA).
f.bliefert@ca-akademie.de

turierter Blick auf die tatsächliche Ausgangslage. Der folgende Check bietet genau das: eine pragmatische Standortbestimmung entlang der vier zentralen Erfolgsdimensionen.

Dimension 1: Daten und Technologie

Zentrale Frage: Haben wir Zugriff auf verlässliche, strukturierte Daten und können wir diese auch produktiv nutzen?

Data Science im Controlling steht und fällt mit der Verfügbarkeit, Qualität und Zugänglichkeit der zugrunde liegenden Daten. Während viele Unternehmen sich früh mit Modellierung oder KI-Werkzeugen beschäftigen, zeigt die Praxis: Bevor überhaupt der erste Forecast erstellt oder eine Anomalie erkannt werden kann, müssen grundlegende Voraussetzungen geschaffen sein.

Checkpunkte:

- **Datenzugriff:** Können relevante Datenquellen (ERP, CRM, HR) konsolidiert und automatisiert bereitgestellt werden? Einfache CSV-Exporte mögen für Experimente ausreichen, doch nachhaltige Anwendungen erfordern einen geregelten Zugriff über Datenbanken, APIs oder Data-Warehouse-Strukturen.
- **Datenqualität:** Sind Definitionen einheitlich? „Vollzeitäquivalente“, „Absatz“ oder „Planversion“ müssen im gesamten Unternehmen die gleiche Bedeutung haben. Selten scheitern Initiativen an zu wenigen Daten, sondern daran, dass bestehende Daten inkonsistent, verspätet oder unterschiedlich interpretiert sind.
- **Tool-Integration:** Moderne Controlling-Teams arbeiten heute nicht mit einem einzelnen Werkzeug, sondern mit einem integrierten Tool-Stack: Excel für Explorationen, Power BI für Visualisierungen, Python für anspruchsvollere Analysen. Können diese Werkzeuge miteinander kommunizieren? Eine einzelne Excel-Datei auf einem Netzlaufwerk ist kein nachhaltiger Datenfluss.
- **Ausführungsumgebung:** Können Python-Modelle automatisiert ausgeführt werden? Gibt es eine Testumgebung für Modellversionen? Spätestens bei operativ eingesetzten Modellen braucht es eine skalierbare und ausfallsichere Infrastruktur, egal ob VM auf einem On-Premise-Server oder eine Cloud-Umgebung.

Bewertung: Wenn mehr als zwei dieser Punkte mit „Nein“ oder „Teilweise“ beantwortet werden, sollte die technische Basis gestärkt werden, bevor komplexe Use Cases angegangen werden.

Dimension 2: Rollen und Organisation

Zentrale Frage: Sind Verantwortlichkeiten klar definiert, oder entstehen Reibungsverluste an Schnittstellen?

Data Science ist Teamarbeit. Kein Bereich kann alle Aufgaben allein abdecken, und das ist auch nicht notwen-

dig. Entscheidend ist vielmehr, dass die Rollen entlang des gesamten Analyseprozesses definiert sind und jeder weiß, wofür er verantwortlich ist. Dabei geht es nicht um formale Jobtitel, sondern um funktionale Rollen, die unabhängig von der Organisationsgröße besetzt werden können und gerade in kleinen Unternehmen oft in Personalunion ausgeübt werden.

Checkpunkte:

- **Controlling als fachlicher Treiber:** Ist klar, dass Controller die Fragestellung definieren, die Modelllogik bewerten und für die inhaltliche Qualität verantwortlich sind? Sie sind Vermittler zwischen Technik und Business, übersetzen Modellannahmen in betriebswirtschaftliche Aussagen und interpretieren Ergebnisse im Kontext der Unternehmenssteuerung.
- **Data Science Kompetenz:** Gibt es Personen (intern oder extern), die methodisch und technisch umsetzen können? Diese entwickeln Modelle, setzen Features um, testen Algorithmen und optimieren die Prognosegüte, natürlich in enger Zusammenarbeit mit den Controllern.
- **IT und Data Engineering:** Ist sichergestellt, dass Daten automatisiert bereitgestellt, Prozesse sicher betrieben und Modelle in die Landschaft integriert werden? Trigger, Datenpipelines, Berechtigungen, Monitoring und Fehlerbehandlung liegen in diesem Verantwortungsbereich.
- **Data Ownership:** Gibt es klare Verantwortlichkeit für die fachliche Richtigkeit und Definition der Daten? Ohne diese Klarheit können Modelle zwar technisch funktionieren, liefern aber Ergebnisse, die im Management nicht akzeptiert werden.

Bewertung: Fehlende Klarheit in diesen Rollen führt unweigerlich zu Verzögerungen, Doppelarbeiten oder Projektabbrüchen. Eine bewusst definierte Governance ist kein bürokratisches Hindernis, sondern ein klarer Rahmen, der Geschwindigkeit, Transparenz und Qualität zugleich ermöglicht.

Dimension 3: Governance und Compliance

Zentrale Frage: Gibt es klare Leitplanken für den verantwortungsvollen Einsatz von Data Science?

Governance, Richtlinien und Compliance definieren den Rahmen, innerhalb dessen datengetriebene Modelle entwickelt, genutzt und überwacht werden. Ohne diesen Rahmen entstehen Risiken, Unsicherheiten und im schlimmsten Fall Entscheidungen, die weder nachvollziehbar noch überprüfbar sind.

Checkpunkte:

- **Datenschutz und -sicherheit:** Sind personenbezogene Daten geschützt? Werden Anforderungen der DSGVO erfüllt? Compliance umfasst übrigens nicht nur Datenschutz, sondern auch Datensicherheit.

- **Dokumentationspflichten:** Sind Modelle nachvollziehbar dokumentiert? Insbesondere Eingangsgrößen, Annahmen, Trainingsdaten und Entscheidungslogiken? Der EU AI Act fordert explizit Transparenz und Erklärbarkeit für Systeme in Entscheidungsprozessen. Ein Forecast-Modell oder eine Kostenstellensimulation gehört typischerweise dazu. Auch die Business Judgement Rule verlangt eine Dokumentation, wie und auf Basis welcher Informationen eine Entscheidung gefällt wurde.
- **Ethische Leitplanken:** Gibt es Mechanismen, um Bias, Fehlanwendungen oder unerwartete Modellwirkungen zu erkennen und zu korrigieren? Modelle können unbeabsichtigt Verzerrungen erzeugen, etwa wenn historische Daten alte Strukturen fortschreiben.
- **Klare Freigabeprozesse:** Wer darf welche Modelle produktiv einsetzen? Welche Qualitätsstandards müssen erfüllt sein?

Bewertung: Governance ist kein Hindernis, sondern ein Beschleuniger. Sie schafft Vertrauen in Daten, sorgt für einheitliche Entscheidungen und ermöglicht es, Modelle skalierbar einzusetzen.

Dimension 4: Kultur und Change-Bereitschaft

Zentrale Frage: Ist die Organisation kulturell bereit, datengetrieben zu arbeiten?

Technologie, Datenqualität und Rollenklärung sind wichtige Voraussetzungen, doch sie reichen nicht aus. Mindestens ebenso entscheidend ist die Frage, ob eine Organisation kulturell bereit ist, datengetrieben zu arbeiten. Das bedeutet nicht, dass alle zu Data Scientists werden müssen, sondern dass Entscheidungen konsequent auf Basis von Daten, Transparenz und Lernbereitschaft getroffen werden.

Checkpunkte:

- **Fehlertoleranz:** Werden datengetriebene Prognosen als das akzeptiert, was sie sind – nämlich Prognosen und keine Garantien? Viele Organisationen sind es gewohnt, Plan- und Forecastwerte als „Verpflichtung“ zu betrachten. Ein reifes Datenverständnis akzeptiert jedoch, dass jede Prognose von Unsicherheiten begleitet ist und dass Fehler nicht Ausdruck von

Inkompetenz sind, sondern Teil eines Lernprozesses.

- **Experimentierfreude:** Gibt es Räume, in denen Prototypen erlaubt sind, in denen neue Ansätze getestet und auch verworfen werden dürfen? Data Science lebt von Iterationen, Tests und Pilotphasen. Ziel ist nicht der perfekte erste Versuch, sondern der schnelle Lerneffekt („fail fast, learn fast“).
- **Transparenz:** Werden Annahmen, Quellen und Logiken offen kommuniziert, nicht nur zwischen Controlling und Data Science, sondern auch gegenüber Fachbereichen und Management? In einer Kultur der Transparenz werden Modelle nicht hinter verschlossenen Türen gebaut, sondern gemeinsam hinterfragt. Modellgrenzen werden offen angesprochen, Sensitivitäten erläutert und alternative Szenarien gemeinsam diskutiert.
- **Führungsunterstützung:** Wird Data Science aktiv von der Führung unterstützt und vorgelebt? Führungskräfte müssen Prognosen als Orientierungsgrößen nutzen, datenbasierte Argumente einfordern und experimentelle Arbeit unterstützen. Ohne diese Unterstützung „von oben“ bleiben datengetriebene Initiativen oft isoliert in Pilotbereichen stecken.

Bewertung: Der Übergang von deterministischen Plänen hin zu datenbasierten Forecasts ist nicht nur eine technische Veränderung, sondern eine kulturelle. Ohne diese Haltung können selbst die beste Methodik und modernste Modelllandschaft keine Wirkung entfalten.

Vom Check zur Handlung: Was nun?

Die ehrliche Auseinandersetzung mit diesen vier Dimensionen zeigt schnell, wo Handlungsbedarf besteht. Dabei gilt: Nicht alle Dimensionen müssen auf höchstem Niveau erfüllt sein, bevor erste Schritte möglich sind. Entscheidend ist vielmehr, die größten Lücken zu identifizieren und gezielt zu schließen.

Typische Handlungsfelder:

- **Schwache technische Basis?** Beginnen Sie mit einem überschaubaren Pilotprojekt auf Excel-Basis, um Methodik zu etablieren, bevor Sie in Infrastruktur investieren.
- **Unklare Rollen?** Organisieren Sie einen Workshop mit allen Stakeholdern, um Verantwortlichkeiten zu klären und ein gemeinsames Verständnis zu schaffen.
- **Fehlende Governance?** Starten Sie mit einem Minimal-Framework: Dokumentationsstandards, Freigabeprozesse und eine klare Data-Owner-Struktur.
- **Kulturelle Hürden?** Setzen Sie auf Quick Wins: kleine, schnell sichtbare Erfolge schaffen Vertrauen und Momentum für größere Veränderungen.

Data Science im Controlling ist kein Sprint, sondern ein Marathon. Die Frage ist nicht, ob wir perfekt vorbereitet sind, sondern ob wir die nächsten sinnvollen Schritte kennen und konsequent gehen. Dieser Check ist der Kompass für diese Reise – nutzen Sie ihn, um Ihre Organisation gezielt voranzubringen. ■



- **Künstliche Intelligenz und Machine Learning im Controlling einsetzen**
- **Anwendung von Excel, Python oder KNIME**
- **KI-Agents in Forecasting, Reporting und Analyse nutzen**

Künstliche Intelligenz und Data Science verändern die Arbeitsweise im Controlling grundlegend. Das Buch von Florian Bliefert hilft, die Funktionsweise von KI zu verstehen, passende Tools auszuwählen und gezielt einzusetzen, eigene Anwendungsfälle umzusetzen und KI verantwortungsvoll zu nutzen. Anhand von Best Practices sowie typischer Fallstricke wird gezeigt, worauf bei der Einführung datengetriebener Methoden zu achten ist.

