



KW 1 KW 2 KW 3 KW 4 KW 5 KW 6 KW 7 KW 8 KW 9 KW 10 KW 11 KW 12 KW 13

# Muster statt Mittelwerte

WHITE PAPER

## **Von Durchschnittswerten zu belastbaren Korridoren in der Liquiditätsplanung**

April 2026

Axel Meythaler | Pirmin Mutter | Pascal Krawczyk

# Inhalt

- 01** Prognoseunschärfe im operativen Cashflow

---

  - 02** Was Zahlungsverhalten wirklich treibt

---

  - 03** Fünf Reifegrade: Wo steht Ihr Unternehmen?

---

  - 04** Blick zurück: Vom Transaktionsbeleg zum Zahlungsprofil

---

  - 05** Blick nach vorne: Muster statt Mittelwerte

---

  - 06** Implementierung

---

  - 07** Business Case

---

  - 08** Ihr Einstieg
-

---

# Das Wichtigste in Kürze

Die **Liquiditätsplanung** gehört zu den **kritischsten Steuerungsinstrumenten** eines Unternehmens. Trotz zunehmender Digitalisierung der Planungsprozesse bleibt die **Prognosegenauigkeit** in vielen Unternehmen unbefriedigend. Die Ursache liegt selten im Planungstool allein, sondern in den **Annahmen, die in die Prognose einfließen**. Insbesondere das **Zahlungsverhalten von Debitoren und gegenüber Kreditoren** ist häufig **Treiber von Ungenauigkeiten**.

Die **Zinswende** hat den **Wandel** zur **aktiven Liquiditätssteuerung** erzwungen. Jeder Euro, der unnötig als **Liquiditätsreserve** gehalten wird, verursacht **Opportunitätskosten**. Jeder Euro, den die Liquiditätsprognose nicht erfasst, kann zu teurer kurzfristiger **Notfinanzierung** führen.

**Process Mining und KI-Methoden** können dabei helfen, **Ungenauigkeiten zu reduzieren** und Planer in die Lage versetzen, **Prognoseintervalle** auszugeben, die es ermöglichen, **Liquiditätsreserven und Kreditlinien risikoadjustiert zu steuern**. **Process Mining** kann dabei bereits ab dem Auftragseingang ansetzen und Ereignisse aus Auftragsanlage, Lieferung, Fakturierung und Freigabeprozess als Kontextmerkmale nutzen, um die **Treiber des nachgelagerten Zahlungsverhaltens sichtbar** zu machen. Auf dieser Datenbasis können **KI-Modelle** trainiert werden, die je offener Forderung und Verbindlichkeit eine **Zahlungsprognose mit Wahrscheinlichkeitsverteilung** erstellen.

So werden Einzahlungs- und Auszahlungstermine nicht nur genauer, sondern vor allem steuerbarer. Unternehmen, die diesen Ansatz implementieren, können ihre **Prognosequalität verbessern**, **Liquiditätsreserven gezielter dimensionieren** und **Finanzierungskosten senken**.

# 01

## Die Prognoseunschärfe im operativen Cashflow

---

Viele Unternehmen haben in den letzten Jahren in moderne Planungssoftware investiert. Die Prozesseffizienz steigt, doch die Prognosegenauigkeit bleibt häufig hinter den Erwartungen zurück.<sup>[9]</sup>

Neben Prozessintegration sind die Prognoseannahmen selbst eine häufige Fehlerquelle: Die Diskrepanz zwischen angenommenem und tatsächlichem Zahlungsverhalten ist in vielen Unternehmen hoch.

### *Die kurzfristige Liquiditätsplanung*

Die **kurzfristige Liquiditätsplanung** basiert in den ersten Planwochen auf der unmittelbaren Erfassung zahlungswirksamer Ein- und Auszahlungen in einer rollierenden Prognose. Die **Liquiditätsplanung** insgesamt folgt einem mehrstufigen Aufbau, der sich in folgende Planungsbausteine gliedern lässt:

**Liquiditätsstatus:** Ermittlung der sofort verfügbaren liquiden Mittel (insbesondere Barmittel, Bankguthaben, freie Kreditlinien) und Gegenüberstellung mit zum Stichtag fälligen Verbindlichkeiten zur Feststellung von Unter- oder Überdeckung (auch als „Pro-Forma-Liquidität“ bezeichnet). Auch nicht verbuchte (und ggf. bereits fällige) Positionen müssen einbezogen werden.

**Offene Posten (OPOS):** Integration der debitorischen und kreditorischen offenen Posten, die nach dem Stichtag fällig werden.



---

Grund dafür ist, dass das tatsächliche Zahlungsverhalten signifikant von den vertraglich vereinbarten Zahlungszielen abweichen kann. Das hat eine unmittelbare Ergebniswirkung. Ein Beispiel: liegt für den tatsächlichen Zahlungstag bei einem Kunden mit 10 Mio. EUR brutto Monatsumsatz und 30 Tagen vertraglichem Zahlungsziel eine Streuung von  $\pm 12$  Tagen vor, entspricht das einer wöchentlichen Prognosebandbreite von rund 4 Mio. EUR. Damit ist eine signifikante Liquiditätsreserve vorzuhalten.

In der Praxis versuchen Unternehmen, diese Unschärfe durch manuelle Korrekturen oder pauschale Sicherheitsaufschläge aufzufangen. Beides hat Grenzen. Manuelle Korrekturen sind personenabhängig, schlecht skalierbar und in ihrer Treffsicherheit selten systematisch überprüft. Pauschale Aufschläge binden unnötig Liquidität. Hinzu kommt ein häufiger Trugschluss: Die Annahme, dass sich Abweichungen einzelner Kunden auf Portfolioebene gegenseitig ausgleichen, trifft nur zu, wenn die Abweichungen tatsächlich unkorreliert sind. Saisonale Effekte, branchenweite Zahlungszyklen oder konjunkturelle Einflüsse können

jedoch systematisch in die gleiche Richtung wirken und die Gesamtabweichung verstärken, anstatt sie zu glätten.

Tools verbessern die Prozesseffizienz und Datenintegration, adressieren aber nicht die Qualität der zugrundeliegenden Prognoseannahmen. Ein entscheidender Hebel liegt in einer empirisch fundierten Datenbasis über das reale Zahlungsverhalten. Process Mining und künstliche Intelligenz (KI) können diese Datenbasis liefern. Der Prognosegegenstand dieses Beitrags bleibt die zeitliche Einordnung bestehender Forderungen und Verbindlichkeiten in der kurzfristigen Liquiditätsplanung. Die Datenbasis dafür kann jedoch deutlich weitervorgelagert sein und bereits Signale aus Vertriebsbeleg, Lieferung, Fakturierung, Mahnwesen oder Freigabeprozess einbeziehen. Das Vertriebsrisiko (ob ein erwarteter Auftrag realisiert wird) und die Ausfallwahrscheinlichkeit (ob überhaupt gezahlt wird) sind mit verwandten KI-Methoden ebenfalls modellierbar, aber nicht Gegenstand dieses Beitrags.



All models are wrong, but some are useful.

George E. P. Box | Science and Statistics

# 02

## Was Zahlungsverhalten wirklich treibt

---

Die Faktoren, die das Zahlungsverhalten bestimmen, sind der Schlüssel zur Prognosegüte im kurzfristigen Planungshorizont.

### ***Debitoren: Warum Kunden anders zahlen als vereinbart***

Zahlungsverhalten wird von zeitlichen, vertraglichen und strukturellen Faktoren beeinflusst. Zeitliche Muster (keine Zahlungsläufe am Wochenende, Feiertags- und Urlaubseffekte, unterschiedliche Bankkalender internationaler Konzerne) sind grundsätzlich gut modellierbar, erhöhen aber die Komplexität der tagesgenauen Prognose.

**Vertragliche Zahlungsziele und WAT.** Die einfachste Modellierung des Zahlungsverhaltens basiert auf den vertraglich vereinbarten Zahlungszielen. Die gewichtete Kennzahl wird als WAT (Weighted Average Terms) bezeichnet.<sup>[10]</sup>

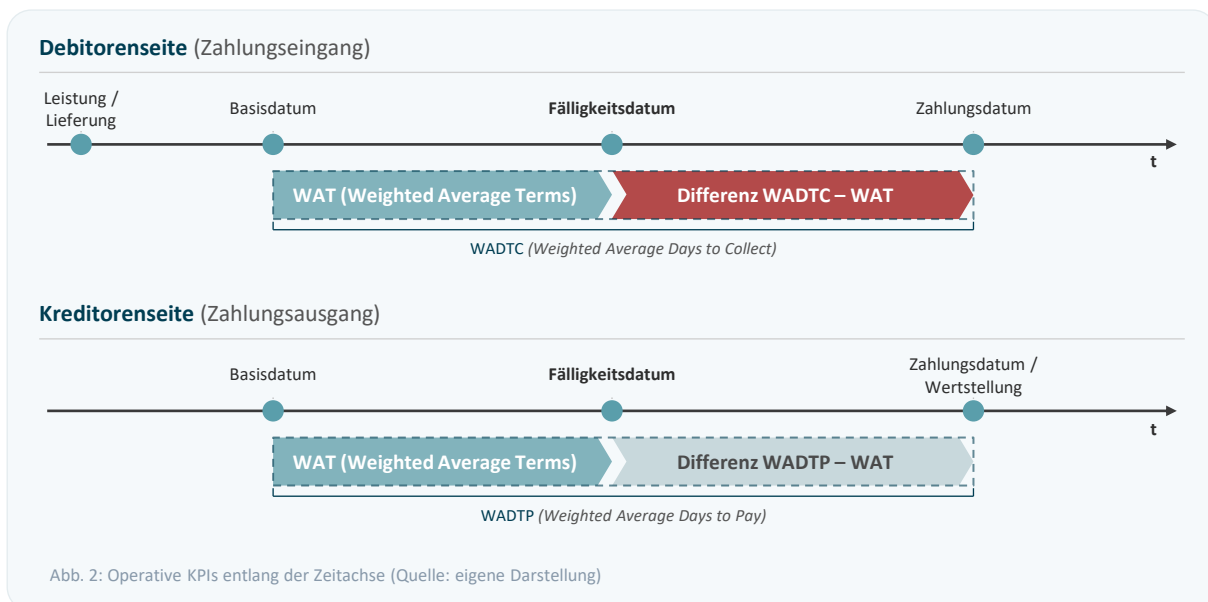
**Das tatsächliche Zahlungsverhalten als empirische Verbesserung.** Die Nutzung der tatsäch-

lichen Dauer vom Rechnungsdatum bis zum liquiditätswirksamen Zahlungseingang, als WADTC (Weighted Average Days to Collect) bezeichnet,<sup>[10]</sup> kann eine empirisch messbare Verbesserung der Prognosegüte bewirken. Die Kennzahl bildet jedoch nur einen gewichteten Durchschnitt über historische Transaktionen ab und kann auf die Zukunft angewandt deshalb im Einzelfall zu großen Verzerrungen führen.

Abbildung 2 zeigt ein Schema der KPI-Definitionen zur Verdeutlichung.

**Grenzen von Durchschnittswerten.** Je höher die Streuung des Zahlungsverhaltens, desto weniger genau bildet ein einzelner Durchschnittswert die Realität ab.

**Einflussfaktoren auf den Zahlungseingang.** Eine möglichst genaue Einzahlungsprognose erfordert die Berücksichtigung zusätzlicher Aspekte: zum Beispiel Teilzahlungen, Skontonutzung (und deren Abhängigkeit von Rechnungshöhe und Zahlungszeitpunkt), Zahlungslauf-Muster des Kunden, Zeitpunkt der Rechnungserstellung, aktuelle Mahnstufe, und die Anzahl offener Zahlungsunstimmigkeiten.



Hinzu kommen strukturelle Faktoren: Regionale Zahlungskulturen, Branchenzugehörigkeit und saisonale Effekte (z.B. Werksferien, Jahresendgeschäft, Budgetabflüsse in Q4) können vorhersagbare, aber häufig nicht modellierte Schwankungen erzeugen.

Die Prognoserelevanz variiert je nach Geschäftsmodell. Bei projekt- und anlagenlastigen Unternehmen erzeugen Teilfaktura und hohe Einzelbelege starke Streuung. In Umfeldern mit häufigen Verrechnungen und Abzügen verzerren Sammelzahlungen und standardisierte Zahlungsläufe einfache Durchschnittsannahmen systematisch. Bei saisonalen Geschäftsmodellen kommen wiederkehrende, aber selten modellierte Muster an Quartalsenden hinzu. Im internationalen B2B-Geschäft erhöhen unterschiedliche Bankkalender und regionale Zahlungskulturen die Varianz zusätzlich.

## **Kreditoren: Warum das eigene Zahlungsverhalten überraschen kann**

Analog zur Einzahlungsprognose lässt sich eine Auszahlungsprognose auf Basis vergangener Erfahrungswerte optimieren. Der WADTP

(Weighted Average Days to Pay)<sup>[10]</sup> misst die gewichtete durchschnittliche Zeitspanne vom Rechnungsdatum bis zur eigenen liquiditätswirksamen Zahlung, gewichtet nach Rechnungsbetrag.

Die Prognosegüte auf der Auszahlungsseite sollte tendenziell höher sein, da Auszahlungen stärker steuerbar sind. Dennoch existieren auch hier systematische Muster, die oft unbewusst entstehen: Rechnungsfreigaben stocken zu bestimmten Monatszeitpunkten (etwa aufgrund interner Reporting-Deadlines), Zahlungsläufe laufen nur an bestimmten Wochentagen, und die Skontonutzung ist häufig inkonsistenter als angenommen. Viele Unternehmen kennen das Zahlungsverhalten ihrer Kunden besser als ihr eigenes, weil die eigenen Auszahlungsmuster über verschiedene Fachbereiche, Freigabestufen und Zahlungsläufe verteilt sind und nie konsolidiert analysiert werden.

Die Analyse dieser Muster hat einen doppelten Nutzen: Sie verbessert die Prognosegenauigkeit und deckt gleichzeitig Optimierungspotenziale auf (z.B. entgangenes Skonto durch langsame Freigabeprozesse). Durch die *alleinige* Nutzung historischer Durchschnitte kann das Potenzial, die Prognosegüte zu steigern, jedoch nicht gehoben werden.

# 03

## Fünf Reifegrade: Wo steht Ihr Unternehmen?


In der Praxis lassen sich fünf Reifegradstufen in der Liquiditätsprognose unterscheiden. Die Einordnung hilft, den Status quo zu bewerten und den Zielpfad für eine Verbesserung zu definieren. Die folgende Darstellung konzentriert sich auf die Einzahlungsprognose, weil dort die größte Prognoseherausforderung liegt: Einzahlungen hängen vom Verhalten externer Geschäftspartner ab und entziehen sich der direkten Steuerung. Die Kreditorenseite ist konzeptionell analog aufgebaut, in der Praxis stärker kontrollierbar (vgl. Kapitel 2).

Abbildung 3 ordnet die Prognosemethodik in fünf Reifestufen ein.

**Stufe 1: Manuell.** Die Liquiditätsprognose erfolgt überwiegend in Tabellenkalkulationen. Zahlungszeitpunkte werden auf Basis der vertraglichen Zahlungsziele geplant, ohne empirische Korrektur. Ein systematischer Soll-Ist-Vergleich findet nicht oder nur sporadisch statt. Die Planung ist personenabhängig, schlecht dokumentiert und bei Personalwechseln fragil. Typisches Merkmal: Prognoseabweichungen werden nicht systematisch analysiert. Die Ursachen für Planverfehlungen bleiben unbekannt.

**Stufe 2: Standardisiert.** Der Planungsprozess ist strukturiert und dokumentiert. Erstmals wird empirisch gemessenes Zahlungsverhalten als Korrektur herangezogen: Die umsatzstärksten Kunden erhalten einen individuellen WADTC, die übrigen Debitoren werden über Segment- oder Branchendurchschnitte abgebildet. Die Aktualisierung erfolgt typischerweise im Rahmen der Jahresplanung. Ein regelmäßiger Soll-Ist-Abgleich ist etabliert. Saisonale Schwankungen, größenabhängige Effekte und die Streuung innerhalb eines Segments bleiben unsichtbar.

**Stufe 3: Integriert.** Die Datenanbindung an das ERP-System (Enterprise Resource Planning) ist automatisiert. Ist-Daten fließen regelmäßig in die Planungssoftware ein. Der Planungsprozess ist rollierend und szenariofähig. Der Fortschritt gegenüber Stufe 2 liegt in Granularität und Aktualität: Der WADTC wird automatisiert pro Debitor berechnet und regelmäßig aktualisiert, nicht mehr nur für Top-Kunden und nicht mehr nur einmal jährlich. Es bleibt jedoch ein Einpunkt-Schätzer pro Debitor: ein einzelner Erwartungswert, der die gesamte Varianz des Zahlungsverhaltens in eine Zahl verdichtet.



Typisches Merkmal: Die Planung ist systemgestützt, aber der Planungsersteller korrigiert regelmäßig „nach Bauchgefühl“, weil ein einzelner Durchschnittswert die Realität nicht ausreichend abbildet.

Der Sprung von Stufe 3 zu 4 erfordert eine Process-Mining-Methodik, die über aggregierte ERP-Kennzahlen hinausgeht.

**Stufe 4: Datengetrieben.** Aufbauend auf der integrierten Datenbasis aus Stufe 3 erfolgt der konzeptionelle Sprung: Vom Einpunkt-Schätzer zur Verteilungsfunktion. Das historische Zahlungsverhalten wird systematisch auf Einzelbelegebene analysiert. Process Mining kommt zum Einsatz, um aus den ERP-Transaktionsdaten die realen Zahlungsmuster zu extrahieren. Debitoren werden nicht mehr nach Stammdaten gruppiert (Branche, Region, Umsatzklasse), sondern anhand ihres tatsächlichen Zahlungsverhaltens segmentiert. Anders als die individuelle WADTC-Berechnung in Stufe 3 bildet diese Segmentierung nicht nur den Mittelwert, sondern die vollständige Verteilung pro Cluster ab. Diese Profile werden bei jeder Modellaktualisierung aus den aktuellen Transaktionsdaten nachgezogen.

Typisches Merkmal: Die Streuung innerhalb eines Segments ist erstmals bekannt und quantifiziert. Damit lassen sich bereits auf dieser Stufe Prognoseintervalle ableiten und Liquiditätsreserven datenbasiert statt pauschal dimensionieren.

**Stufe 5: Prädiktiv.** Der höchste Reifegrad kombiniert Process-Mining-Erkenntnisse mit kontextbasierten KI-Modellen. Für jede einzelne offene Forderung wird eine individuelle Zahlungsprognose erstellt, die simultan auf historischem Verhalten, saisonalen Mustern, Rechnungsattributen und dem aktuellen Prozessstatus basiert. Der Sprung gegenüber Stufe 4 ist, dass die multivariate Modellierung Wechselwirkungen zwischen Faktoren berücksichtigt, die eine univariate Verteilung je Segment nicht abbilden kann. Die Prognose ist probabilistisch und liefert Konfidenzintervalle. Die analytische Reifestufe entfaltet ihren vollen Steuerungswert allerdings erst, wenn Governance, Betriebsverantwortung und operative Anbindung an Reservelogik und Liniensteuerung mitziehen.

# Reifegradmodell der Forecastmethodik

VERTEILUNGEN & PRÄDIKTION

## STUFE 5



### Prädiktiv

KI-Modelle auf Einzelbelegebene, multivariat, probabilistisch, mit Governance

*Individuelle Zahlungsprognose pro Beleg statt pro Segment mit Konfidenzintervallen*

## STUFE 4



### Datengetrieben

Process Mining auf Einzelbelegebene, Prognose pro Segment

*Streuung bekannt und quantifiziert, Profile bei jeder Aktualisierung nachgezogen*

## ----- PARADIGMENWECHSEL -----

EINPUNKT-SCHÄTZER

## STUFE 3



### Integriert

Automatisierte ERP-Anbindung, WADTC pro Debitor, regelmäßig aktualisiert

*Granular und aktuell, aber weiterhin Einpunkt-Schätzer*

## STUFE 2




### Standardisiert

WADTC als Korrekturwert für Top-Kunden, Rest als Segment-Durchschnitt

*Erster empirischer Korrekturwert, aber Streuung unsichtbar*

## STUFE 1



### Manuell

Statische Zahlungsziele, kein Soll-Ist-Vergleich

*Abweichungen werden nicht systematisch analysiert*

Abb. 3: Reifegradmodell der Prognosemethodik (eigene Darstellung)

# 04

## Blick zurück: Vom Transaktionsbeleg zum Zahlungsprofil

### *Was Process Mining anders macht*

Process Mining ist eine Analysemethode, die auf Basis strukturierter Prozessprotokolle (Event Logs) aus IT-Systemen den tatsächlichen Ablauf von Geschäftsprozessen rekonstruiert.<sup>[1]</sup>

Eine konventionelle Analyse der Zahlungstransaktionen liefert zwar den WADTC (bis auf Belegebene). Process Mining geht weiter und verknüpft Zahlungseingänge mit den Prozessereignissen entlang des gesamten Belegflusses und rekonstruiert den Prozesspfad vom Vertriebsbeleg bis zum Zahlungseingang. Für die Liquiditätsprognose ist der Abschnitt ab Rechnungsstellung operativ am relevantesten. Vorgelagerte Prozessschritte wie Auftragsart oder Teillieferung fließen als Kontextattribute ein und verbessern die Prognosequalität. Auf der Auszahlungsseite gilt die Logik analog ab Bestellung, Wareneingang und Rechnungsfreigabe. Durch diese Verknüpfung können die Treiber von Zahlungsverzögerungen sichtbar werden. Das vorliegende Kapitel beschreibt den deskriptiven Teil des Ansatzes, also die systematische Analyse historischer Zahlungsmuster. Die darauf aufbauende prädiktive Modellierung mittels KI ist Gegenstand von Kapitel 5.

### *Vom Event Log zum Zahlungsprofil*

Der Weg von den rohen Transaktionsdaten zu verwertbaren Zahlungsprofilen folgt einem strukturierten Analyseprozess.

1

**Datenextraktion und Event-Log-Konstruktion.** Die relevanten Events werden aus dem ERP-System extrahiert und als Event Log strukturiert. Jeder Eintrag enthält mindestens einen Zeitstempel, eine Aktivitätsbezeichnung (z.B. „Rechnung erstellt“, „Zahlung eingegangen“) und eine eindeutige Belegkennung (Case ID).<sup>[1],[2]</sup> Als Case ID dient die einzelne Rechnung, da die Zuordnung von Zahlungseignissen zur Rechnung die granularste auswertbare Einheit darstellt.

2

**Process Discovery.** In einem typischen Order-to-Cash-Prozess zeigen sich häufig Hunderte Prozessvarianten, die mittels Process-Mining-Algorithmen identifiziert werden: Standardabläufe, Abläufe mit Teillieferungen, Gutschriften, Mahnungen und Reklamationen. Jede Variante hat ein eigenes Durchlaufzeitprofil.

---

3

**Zahlungsverhaltens-Analyse.** Für jeden Debitor (oder jedes Debitorenssegment) wird die Verteilung der tatsächlichen Zahlungsdauern berechnet. Das Ergebnis ist eine vollständige Verteilungskurve, die auch den Median, die Streuung, mögliche Häufungen und Ausreißer zeigt.

---

4

**Muster-Identifikation.** Process Mining deckt systematische Muster auf, die in einer konventionellen Analyse unsichtbar bleiben. Typische Erkenntnisse: Saisonale Schwankungen (z.B. beschleunigtes Zahlungsverhalten im Q4 aufgrund von Budgetabflüssen, Verlangsamung im Q1), größenabhängige Effekte (z.B. Skontonutzung nur bei Rechnungen unterhalb bestimmter Schwellenwerte), Wochentags-Effekte bei Zahlungsläufen und Korrelationen mit internen Prozessengpässen (z.B. verzögerte Rechnungsfreigabe um den Monatsabschluss).

---

5

**Segmentierung.** Debitoren werden anhand ihres Zahlungsverhaltensprofils in Cluster gruppiert. Typische Segmente: „pünktliche Zahler“ (geringe Abweichung vom Zahlungsziel), „systematische Verzögerer“ (konsistent spätere Zahlung, aber berechenbar), „saisonale Muster“ (starke Abhängigkeit von Quartal oder Monat), „volatile Zahler“ (hohe Streuung). Diese verhaltensbasierte Segmentierung bildet die Grundlage für differenzierte Prognoseannahmen und liefert zugleich eine Lösung für neue Kunden ohne eigene Zahlungshistorie.

Das Ergebnis der Schritte 1 bis 5 ist ein fundiertes Zahlungsprofil je Debitor auf Basis einer Wahrscheinlichkeitsverteilung der erwarteten Zahlungsdauer, die saisonale, größenabhängige und prozessbedingte Einflussfaktoren berücksichtigt. In Umfeldern mit häufigen Teilzahlungen oder Verrechnungen bezieht sich die Prognose auf den dominanten Zahlungszeitpunkt je Beleg. Diese Profile sind kein Analyseselbstzweck. Sie ersetzen in der rollierenden Liquiditätsplanung starre Fälligkeiten, Durchschnittswerte und pauschale Sicherheitsaufschläge durch belastbarere Annahmen und Korridore.

# End-to-End-Architektur: Prädiktive Liquiditätsprognose

Von Rohdaten zur integrierten Planungs- und Risikosicht

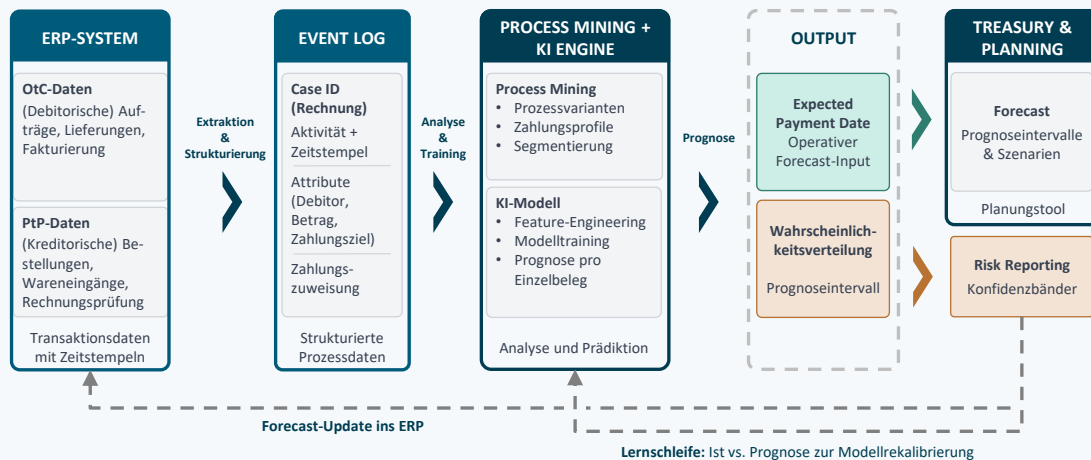


Abb. 4: End-to-End-Architektur: Prädiktive Liquiditätsprognose. Vom ERP-Beleg über Process Mining und KI-Prognose bis zur Planungsschnittstelle mit Governance-Feedback-Loop. (Quelle: eigene Darstellung)

## Integration in die rollierende Planung

Die Integration der Process-Mining-Ergebnisse in den bestehenden Planungsprozess erfolgt gezielt an den Stellen, an denen bisher mit statischen Annahmen gearbeitet wird. Abbildung 4 zeigt die End-to-End-Logik von der ERP-Datenextraktion über Process Mining und KI bis zur Planungsintegration. Die einzelnen Komponenten werden in den Kapiteln 5 und 6 im Detail erläutert.

**Bei den offenen Posten** wird nicht mehr mit dem vertraglichen Zahlungsziel oder WADTC gerechnet, sondern mit dem empirischen Zahlungsprofil des jeweiligen Debtors oder Segments. Für die operative Umsetzung bedeutet das: Das Prognosemodell berechnet je offener Forderung ein erwartetes Zahlungsdatum, das als aktualisiertes Plandatum in das Planungstool übernommen wird. Die Aggregation der Einzelprognosen zur wöchentlichen Einzahlung erfolgt auf Basis der individuellen Wahrscheinlichkeitsverteilungen und ermöglicht die Berechnung von Konfidenzbändern auf aggregierter Ebene. Darüber hinaus können auf dieser Basis Konfidenzszenarien definiert werden:

etwa ein P90-Szenario (der Einzahlungsbetrag, der mit 90 Prozent Wahrscheinlichkeit mindestens erreicht wird) für die konservative Kreditlinien-Steuerung und ein P50-Szenario (Median) für die operative Planung. Das Konfidenzniveau wird damit zu einer expliziten Steuerungsgröße. Das Treasury entscheidet bewusst, wie viel Prognoseunsicherheit es akzeptiert, und dimensioniert Reserven und Kreditlinien entsprechend.

**Auf der Auszahlungsseite** fließen die Erkenntnisse aus dem PtP-Prozess direkt in die Prognose der kreditorischen offenen Posten ein. Statt des theoretischen Fälligkeitsdatums wird ein realistisches Auszahlungsdatum ermittelt, das systematische interne Muster (z.B. verzögerte Rechnungsfreigaben) bereits berücksichtigt. Dabei soll auf der Auszahlungsseite das Vorsichtsprinzip gelten. Die Prognose sollte aber nicht auf der Fortschreibung eigener Prozessschwächen basieren. Interne Verzögerungen verbessern zwar kurzfristig die Liquiditätsposition, sind aber weder planbar noch nachhaltig. Empfehlenswert ist daher, auf der Kreditorensseite das vertragliche Fälligkeitsdatum als Untergrenze zu verwenden und Verzögerungen nur als Sensitivität abzubilden.

---

Der Planungsrhythmus und die bestehenden Planungstools bleiben erhalten, Reporting und Entscheidungslogik werden jedoch erweitert: Konfidenzbänder ermöglichen eine risikoadjustierte Steuerung, die Bandbreite des Forecasts wird zur Steuerungsgröße für Kreditlinien und Reserven.

# 05

## Blick nach vorne: Muster statt Mittelwerte


Process Mining liefert die empirische Grundlage: Zahlungsprofile, Verteilungen und Segmente (vgl. Reifestufe 4). Für ihre Übersetzung in individuelle, kontextbasierte Zahlungsprognosen braucht es den nächsten Schritt: KI-Modelle, die auf historischen Zahlungsmustern und Prozessdaten trainiert werden, erstellen für jede offene Forderung eine individuelle Prognose des erwarteten Zahlungstermins. Auf der Kreditorensseite ist der Ansatz analog anwendbar.

### *Von der Rückschau zur Vorhersage*

Ein Machine-Learning-basiertes (ML) Prognosemodell für Zahlungseingänge nutzt typischerweise Eingangsvariablen (Features) aus vier Kategorien: (1) historisches Zahlungsverhalten des Debtors (WADTC, Varianz, Trend der letzten Perioden), (2) Rechnungsattribute (Betrag, Zahlungsziel, Typ, Gesellschaft), (3) Kontextfaktoren (Monat, Quartal, Feiertage, Mahnstufe, Alter der Forderung, offene Klärungsfälle) und (4) Prozessmerkmale aus dem Process Mining (Prozessvariante, Auftragsart und Liefermodalität als Kontextattribute,

Anzahl Prozessschleifen). Als Algorithmen kommen in der Praxis vor allem Gradient-Boosted Decision Trees (z.B. XGBoost, LightGBM) und Random Forests zum Einsatz. Diese Algorithmen sind für strukturierte, tabellarische Geschäftsdaten gut geeignet und modellieren nicht-lineare Zusammenhänge sowie Interaktionseffekte zwischen Variablen. In der akademischen Literatur und in Praxisprojekten zeigen solche Modelle auf Rechnungsebene konsistent deutliche Verbesserungen gegenüber einfachen Durchschnittsannahmen.<sup>[8]</sup> Die erreichbare Genauigkeit hängt jedoch stark von der Datenqualität, der Kundenstruktur und der Modellkalibrierung ab. Für die Treasury-Steuerung sind der mittlere absolute Prognosefehler in Tagen (auf Einzelbelegebene) und die Kalibrierung der Prognoseintervalle (auf Wochenaggregaten) die relevantesten Qualitätsmaße.<sup>[6]</sup> Die Einführung von Features, die das historische Kundenverhalten abbilden, hat das Potenzial, die Prognose gegenüber reinen Rechnungsattributen signifikant zu verbessern.

Der Vorteil gegenüber einer univariaten Verteilungsfunktion aus dem Process Mining: ML-Modelle berücksichtigen die Wechsel-



wirkungen mehrerer Faktoren simultan. Diese multivariate Modellierung geht über einfache Durchschnittswerte oder segmentbasierte Verteilungen hinaus. Dabei liefert gerade die Process-Mining-Perspektive Features, die aus reinen ERP-Stamm- und Bewegungsdaten nicht ableitbar sind: Die Prozessvariante eines Belegs (z.B. Teillieferung mit Nachfaktorierung) erklärt Zahlungsverzögerungen, die ohne Rekonstruktion des Prozesspfads als unerklärte Varianz im Modell verbleiben würden.

**Vom Punktschätzer zur Verteilung.** Decision Trees liefern zunächst einen Punktschätzer (das erwartete Zahlungsdatum). Für die probabilistische Erweiterung gibt es mehrere etablierte Wege: Die Quantilsregression trainiert das Modell direkt auf bestimmte Perzentile (z.B. "wann zahlt der Kunde mit 90% Wahrscheinlichkeit spätestens?"), anstatt nur den Erwartungswert zu schätzen. Die konforme Vorhersage (Conformal Prediction) nutzt die historischen Prognosefehler des Modells, um nachträglich kalibrierte Prognoseintervalle zu erzeugen, ohne das Modell selbst zu verändern.<sup>[3]</sup> Die empirische Residualverteilung aus dem Backtesting wertet aus, wie stark die Prognosen in der Vergangenheit vom Ist abgewichen sind, und leitet daraus Bandbreiten ab. In der Praxis hat sich die Kombination aus Punktschätzung und konformer Vorhersage als robuster Einstieg bewährt:<sup>[4]</sup> Das Verfahren erzeugt auf Basis historischer Residuen kalibrierte Prognoseintervalle, erfordert keine Modelländerung und ist direkt prüfbar (z.B. „Wenn das Modell ein 80%-Prognoseintervall ausgibt, sollten im Rückblick tatsächlich rund 80% der realisierten Zahlungseingänge innerhalb dieses Intervalls gelegen haben.“). Die formale Kalibrierung gilt dabei unter hinreichend stabilen Datenverteilungen. Bei signifikanten Verschiebungen im Zahlungsverhalten muss die Kalibrierung laufend überwacht und gegebenenfalls neu justiert werden.

Für die Steuerungsentscheidung bedeutet das: Das Treasury erhält nicht mehr eine einzelne Zahl, sondern einen kalibrierten Korridor mit klarer Aussage darüber, wie viel Reservepuffer die aktuelle Prognoseunsicherheit erfordert.

# Bandbreiten statt Punktwerte

Bereits auf Basis der Process-Mining-Verteilungen (Reifestufe 4) lassen sich Konfidenzbänder ableiten. Der Mehrwert der KI-Modellierung liegt in der Präzision dieser Bänder: Weil das Modell mehrere Einflussfaktoren simultan berücksichtigt, werden die Intervalle enger und damit operativ nützlicher. Der operativ wertvollste Output eines KI-gestützten Prognoseansatzes ist die probabilistische Prognose. Statt einer einzelnen Planaussage („In KW 24 erwarten wir Einzahlungen aus Forderungen von 14,3 Mio. EUR“) liefert das Modell ein Prognoseintervall („Mit 90 Prozent Wahrscheinlichkeit liegen die Einzahlungen aus Forderungen in KW 24 zwischen 13,1 und 15,8 Mio. EUR“). Dieses Intervall bezieht sich auf den Working-Capital-nahen Anteil des Cashflows (Einzahlungen aus Forderungen, Auszahlungen an Lieferanten).

Abbildung 5 visualisiert den Unterschied zwischen einer punktwertbasierten und einer intervallbasierten Liquiditätsprognose.

Das Treasury steuert entlang der Perzentile der aggregierten wöchentlichen Einzahlungen.

P90 für die konservative Kreditlinien-Dimensionierung, P50 für die operative Planung.

Im operativen Alltag ändert sich damit die Steuerungslogik. Das Treasury-Team steuert Handlungen entlang der Bandbreite. Bei engem Band (hohe Sicherheit) kann die Liquiditätsreserve reduziert oder das freie Kapital kurzfristig angelegt werden. Bei weitem Band (hohe Unsicherheit) wird die Kreditlinie vorsorglich aufgestockt oder eine anstehende Auszahlung zeitlich verschoben.

Während das Modell den Prognosefehler auf Einzelbelegebene in Tagen misst, ist die operative Steuerungskennzahl der prozentuale Prognosefehler auf Wochenaggregaten, weil das Treasury auf dieser Ebene plant. Die Qualität der probabilistischen Prognose lässt sich direkt prüfen: Gibt das Modell ein 80%-Konfidenzband aus, sollten im Rücktest tatsächlich rund vier von fünf Zahlungseingängen innerhalb dieses Bandes liegen.<sup>[3]</sup> Diese Kalibrierungsquote ist die zentrale Qualitätskennzahl des Forecasts.

## Punktwertbasierte vs. intervallbasierte Liquiditätsprognose

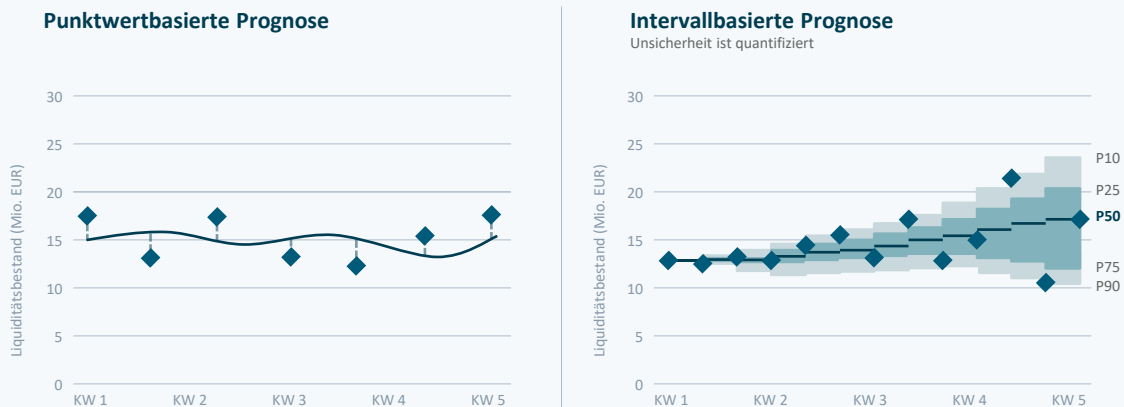


Abb. 5: Punktwertbasierte versus intervallbasierte Liquiditätsprognose. Rauten zeigen tatsächliche Liquidität. Das Prognoseintervall macht Planungsunsicherheit quantifizierbar und ermöglicht risikoadjustierte Entscheidungen. P90 bezeichnet den Wert, der mit 90 Prozent Wahrscheinlichkeit erreicht wird. (Eigene Darstellung, fiktive Werte)

---

Das ML-Modell überführt einen Teil dieser Streuung in erklärte Variation, indem es sie auf konkrete Treiber zurückführt (z.B. Rechnungshöhe, Saisonalität, Prozessvariante). Die verbleibende, nicht erklärbare Restvarianz ist kleiner. Damit werden die Prognoseintervalle enger, ohne an Zuverlässigkeit zu verlieren.<sup>[6]</sup> Der operative Kern des Ansatzes ist also, nicht die Unsicherheit zu ignorieren, sondern den unerklärten Anteil systematisch zu reduzieren.

Die Wochenkorridore entstehen dabei nicht durch bloße Addition erwarteter Zahlungstermine, sondern durch simulationsbasierte Aggregation der Einzelverteilungen. Mittels Monte-Carlo-Simulation werden gemeinsame Einflussfaktoren wie Saisonalität, Branchenkonjunktur und Zahlungslaufmuster als korrelierte Störgrößen berücksichtigt. Das Ergebnis ist ein Korridor, der Portfolioeffekte realistisch abbildet, statt Unabhängigkeit der Einzelpositionen zu unterstellen. So lassen sich Konfidenzscenarien für die operative Planung und die Kreditliniensteuerung belastbar ableiten.

## *Wie die Prognose mit der Zeit besser wird*

**Erklärbarkeit als Voraussetzung für Akzeptanz.** Ein Prognosemodell, das niemand versteht, wird niemandem nutzen. Wenn das Modell für einen Debitor eine deutlich spätere Zahlung prognostiziert, muss der Planungsverantwortliche diese Einschätzung gegenüber dem CFO, dem Vertrieb oder dem Credit Management begründen können. Sogenannte Feature-Importance-Analysen und SHAP-Werte (Shapley Additive Explanations)<sup>[5]</sup> machen das möglich. Sie zerlegen jede Einzelprognose in ihre Treiber und machen sie nachvollziehbar (z.B. „Haupttreiber: Rechnungsbetrag über 500.000 € + Kunde hat in den letzten 3 Monaten 15 Tage langsamer gezahlt + Q1-Effekt“). Damit kann der Planer jede Abweichung vom bisherigen Planwert mit konkreten, datengestützten Argumenten erklären. Diese Transparenz ist entscheidend dafür, dass das Modell im operativen Alltag bestehen kann. Ebenso wichtig ist die Erklärbarkeit im Plan-Ist-Abgleich: Wenn eine prognostizierte Zahlung ausbleibt oder deutlich später eingeht, lässt sich anhand der Feature-Beiträge nachvollziehen, welche Annahme nicht eingetreten ist (z.B. "Das Modell hat auf Basis des historischen Q4-Musters eine beschleunigte Zahlung erwartet, der Kunde hat jedoch seinen Zahlungslauf umgestellt"). Damit wird der Prognosefehler nicht nur quantifiziert, sondern auf seine wichtigsten Prognosetreiber zurückgeführt. Das unterscheidet ein lernendes System von einer „Black Box“.

**Die Lernschleife.** Der Schlüsselgedanke ist das kontinuierliche Feedback: Jeder reale Zahlungseingang wird mit der zugehörigen Prognose abgeglichen und fließt in die nächste Modellaktualisierung ein. In einem konventionellen System werden Prognosefehler im besten Fall nachträglich analysiert und führen zu manuellen Anpassungen. In einem lernenden System erfolgt diese Anpassung strukturiert und datenbasiert.

Zahlungsverhalten verändert sich über die Zeit, sei es durch konjunkturelle Verschiebungen, veränderte Zahlungsbedingungen oder eigene Maßnahmen wie angepasstes Mahnwesen.<sup>[7]</sup> Diese Verschiebungen lassen sich im laufenden Prognosemonitoring systematisch erkennen und bei der periodischen Modellaktualisierung berücksichtigen.

Der direkteste Weg, Policy-Effekte abzubilden, ist ihre explizite Kodierung als Feature: Ein Wechsel der Mahnstrategie, eine Anpassung der Zahlungskonditionen oder eine Änderung der Freigabeprozesse wird als strukturelle Variable im Modell hinterlegt. Damit muss das Modell die Veränderung nicht erst aus den Daten lernen, sondern kann sie ab dem Zeitpunkt der Einführung berücksichtigen. Ergänzend bildet das Modell graduelle Veränderungen über zwei datengetriebene Mechanismen ab: Erstens durch Recency Weighting, das jüngeren Datenpunkten ein höheres Gewicht gibt und so schleichende Verschiebungen automatisch einfängt. Zweitens durch periodisches Retraining auf aktualisierten Daten, das strukturelle Brüche erfasst.

**Governance und Betriebsmodell.** In einem Finanzumfeld darf ein Prognosemodell nicht unkontrolliert „automatisch lernen“. Die Modellaktualisierung erfolgt periodisch (z.B. monatlich) und unterliegt einem definierten Freigabeprozess. Wesentliche Bestandteile sind ein Monitoring der Prognosegenauigkeit (Forecast vs. Ist, z.B. als mittlerer absoluter prozentualer Prognosefehler auf die wöchentlichen Einzahlungen), definierte Schwellenwerte für Rekalibrierung, Auditierbarkeit der Modellergebnisse und ein klarer Eskalationsprozess bei signifikanten Abweichungen. Ebenso muss vor dem Produktivstart geklärt sein, wer das Modell dauerhaft betreibt und wie Strukturbrüche (z.B. M&A, Systemmigrationen, größere Änderungen im Kundenportfolio) behandelt werden.

# 06

## Implementierung

### *Was die Daten können müssen*

Der Erfolg einer Process-Mining- und KI-gestützten Liquiditätsprognose hängt maßgeblich von der Qualität der verfügbaren Daten ab. Folgende Voraussetzungen sollten vor Projektbeginn geprüft werden:

**Historische Datentiefe.** Für belastbare saisonale Muster werden mindestens 24 bis 36 Monate historische Transaktionsdaten benötigt.

**Stammdaten-Qualität.** Debitorenstamm und Kreditorenstamm müssen aktuell und konsistent gepflegt sein. Insbesondere die Zuordnung von Zahlungsbedingungen, Kundensegmenten und regionalen Attributen muss verlässlich sein.

**Zahlungszuordnung.** Eingehende Zahlungen müssen den zugehörigen Rechnungen eindeutig zugeordnet sein. In der Praxis ist dies nicht immer gegeben: Sammelzahlungen ohne Referenz, Verrechnungen, „On Account“-Buchungen und fehlerhafte Zuordnungen im Bankclearing führen dazu, dass die Verknüpfung von Zahlung und Rechnung lückenhaft ist. Wenn ein erheblicher Anteil der Zahlungen manuell ausgeziffert wird und die Zuordnungsqualität niedrig ist, lernt das Modell auf fehlerhaften Daten.

Daher muss nicht selten vor der eigentlichen Analyse eine Phase der Datenbereinigung erfolgen. Diese Vorstufe sollte nicht unterschätzt, aber auch nicht zum Hindernis gemacht werden. Bereits eine Analyse der umsatzstärksten Debitoren mit gut gepflegten Daten kann aussagekräftige Ergebnisse liefern.

### *Technologie-Stack im Überblick*

Der beschriebene Ansatz ist nicht an ein spezifisches Tool gebunden. Die Architektur besteht aus drei funktionalen Schichten (vgl. Abbildung 4):

**Daten- und Process-Mining-Schicht.** Event Logs werden aus dem ERP-System extrahiert und die Prozessanalyse durchgeführt. Etablierte Process-Mining-Plattformen wie Celonis, SAP Signavio, UiPath Process Mining oder Noreja bieten vorgefertigte Konnektoren für SAP und andere ERP-Systeme. In S/4HANA-Umgebungen empfiehlt sich die Extraktion über CDS Views und ACDOCA-basierte Datenmodelle. Alternativ kann die Event-Log-Extraktion mit eigenen ETL-Prozessen (Extract, Transform, Load) realisiert werden.

**Analyse- und ML-Schicht.** Die Zahlungsverhaltens-Analyse und das Training der Prognosemodelle erfolgen über gängige

---

Data-Science-Stacks (Python mit scikit-learn, XGBoost, LightGBM) oder integrierte Analytics-Plattformen wie Databricks. Entscheidend ist weniger die Wahl des Frameworks als die Qualität der Merkmalsbildung und die Integrationsfähigkeit in die bestehende IT-Landschaft.

**Planungs- und Reporting-Schicht.** Die Prognose-Ergebnisse fließen in die bestehende Planungsumgebung ein. Die Integration erfolgt typischerweise über eine automatisierte Datenschnittstelle. Das Prognosemodell schreibt das aktualisierte erwartete Zahlungsdatum und die Konfidenzinformation in eine Schnittstellentabelle, die das Planungstool automatisiert ausliest.

Die Integration der drei Schichten kann schrittweise erfolgen. Ein pragmatischer erster Schritt ist die Durchführung der Process-Mining-Analyse als eigenständige Vorstudie, deren Ergebnisse zunächst manuell in die Planungsparameter übernommen werden.

## *Vier Phasen bis zum Produktivbetrieb*

Eine effektive Implementierung kann in vier Phasen erfolgen, die parallel zum laufenden Planungszyklus umgesetzt werden können. Der beschriebene Implementierungspfad setzt voraus, dass das Unternehmen mindestens auf Reifegrad 2 (strukturierter Planungsprozess mit Zugang zu historischen ERP-Transaktionsdaten) operiert und über eine ausreichende historische Datenbasis verfügt. Die tatsächliche Dauer hängt maßgeblich von der Datenqualität, dem eingesetzten ERP-System, IT-Sicherheitsanforderungen und der Komplexität der Integration ab.

### **Phase 1: Data Readiness und erste Analyse.**

Die Datenqualität und -verfügbarkeit werden geprüft, Event Logs für den OtC-Prozess extrahiert und eine erste Process-Mining-Analyse auf die umsatzstärksten Debitoren durchgeführt. Ergebnis: Erste Zahlungsprofile, identifizierte Datenqualitätsprobleme und erstmals empirische Sichtbarkeit des tatsächlichen Zahlungsverhaltens.

### **Phase 2: Modellentwicklung und Validierung.**

ML-Prognosemodelle werden auf historischen Daten trainiert und gegen Ist-Werte getestet

(z.B. Prognose der Zahlungseingänge der letzten sechs Monate, dann Abgleich mit den tatsächlichen Werten). Ergebnis: Ein validiertes Prognosemodell, dessen Verbesserung gegenüber dem Status quo quantifiziert nachgewiesen werden kann.

**Phase 3: Integration und Parallelfahrt.** Alte und neue Methodik laufen über mehrere Planungszyklen parallel, die Planungsverantwortlichen werden geschult. Ergebnis: Nachweis, dass die Verbesserung auch unter realen Bedingungen hält.

### **Phase 4: Produktivbetrieb und Ausbau.**

Monitoring und Governance-Strukturen werden aufgebaut, die Methodik schrittweise auf weitere Debitorenssegmente, die Kreditorensseite und zusätzliche Planungshorizonte erweitert. Spätestens jetzt muss die Betriebsverantwortung geklärt sein. Wer betreibt das Modell nach Projektende und wie werden Lizenzen und Infrastruktur dauerhaft finanziert?

Bereits in Phase 1 können Quick Wins realisiert werden. Dabei bleiben die bestehenden Prozesse und Systeme zunächst unangetastet und werden schrittweise angereichert. Das reduziert das Implementierungsrisiko und den Veränderungsdruck auf die Organisation.

# 07

## Business Case

Der wirtschaftliche Nutzen entsteht nicht in der Analyse selbst. Er entsteht dort, wo belastbarere Prognosekorridore zu besseren Entscheidungen über Liquiditätsreserven, Liniennutzung und Reaktionsfähigkeit führen. Dieser Nutzen lässt sich auf zwei Ebenen beschreiben. Erstens durch eine robustere Prognose, die die Steuerungsqualität erhöht. Zweitens durch operative Erkenntnisse, die direkt auf das Working Capital wirken.

**Verbesserte Prognosequalität.** Effekte einer robusteren Liquiditätsprognose lassen sich nicht immer direkt in Euro ausdrücken. Die Vorteile liegen dennoch auf der Hand: Das Treasury steuert auf Basis zuverlässigerer Zahlen, der Abstimmungsaufwand zwischen Fachbereichen und Finanzplanung sinkt, und die Reaktionszeit bei Abweichungen verkürzt sich. Teams, die heute mehrere Tage pro Monat mit der manuellen Aufbereitung und Korrektur von Prognosedaten verbringen, können diese Zeit auf wertschöpfende Analysen und Steuerung umlenken. Darüber hinaus ermöglicht eine zuverlässigere Prognose eine vorausschauende Steuerung der Kreditlinien, senkt den notwendigen Liquiditätspuffer und schafft Spielraum für FX-Sicherungsgeschäfte.

**Quantifizierbare Effekte über Working-Capital-Optimierung.** Die Process-Mining-Analyse deckt neben Prognosemustern auch operative Verbesserungspotenziale auf. Auf der Debitorensseite werden verzögerte Rechnungsstellung, langsame Klärungsprozesse und auffälliges Zahlungsverhalten einzelner Debitoren sichtbar, die den Zahlungseingang systematisch hinauszögern und an denen gezieltes Forderungsmanagement ansetzen

kann. Auf der Kreditorensseite zeigt sich, wo Skontofristen ungenutzt verfallen. Ob deren Nutzung ökonomisch sinnvoll ist, hängt vom Einzelfall ab, da frühere Zahlung kurzfristig Liquidität bindet. Diese Erkenntnisse sind nicht Gegenstand des hier beschriebenen Prognoseansatzes, können aber eigenständige Optimierungsinitiativen im Working-Capital-Management anstoßen.



Schon bei mittelständischen Unternehmen summieren sich diese Effekte spürbar. Gebundenes Working Capital wird freigesetzt, der Finanzierungsbedarf sinkt, und nachgelagerte Kostenblöcke wie Liniengebühren, Überziehungszinsen und Prozesskosten im Forderungsmanagement reduzieren sich. Abhängig von Umsatzvolumen und Kundenstruktur bewegen sich die jährlichen Einsparungen im sechsstelligen Bereich. Die Investition für eine Erstimplementierung (Datenextraktion, Modellentwicklung, Pilotintegration) kann sich nicht selten innerhalb von ein bis zwei Jahren amortisieren, vorausgesetzt die Datenqualität ist belastbar und die Betriebsverantwortung klar geregelt.

# 08

## Ihr Einstieg

---

Die Genauigkeit der kurzfristigen Liquiditätsplanung steht und fällt in vielen Fällen mit den Annahmen über das tatsächliche Zahlungsverhalten. Process Mining macht dieses Verhalten sichtbar. Machine Learning/ KI-Methoden überführen diese Erkenntnisse in prädiktive Modelle, die sich über definierte Governance-Prozesse periodisch verbessern.

Der Ansatz ersetzt nicht die bestehende Planungsinfrastruktur, sondern verbessert die Aussagekraft der Prognoseannahmen und erweitert die Entscheidungslogik. Er ist schrittweise implementierbar, kompatibel mit bestehenden Planungstools und Systemlandschaften und liefert bereits in frühen Projektphasen messbare und nachhaltige Ergebnisse.

Die Daten dafür sind in den meisten Unternehmen vorhanden und die Technologie verfügbar. Was fehlt, ist die systematische Auswertung der Transaktionsdaten, die das ERP-System längst erfasst. Unternehmen, die diesen Schritt gehen, verändern nicht nur ihre Prognosequalität. Sie ersetzen die Schätzung einer exakten Zahl durch eine quantifizierte Bandbreite und steuern Liquidität entlang definierter Konfidenzniveaus statt auf Basis einer einzelnen Punktschätzung.

Der entscheidende erste Schritt beginnt somit nicht mit neuer Software, sondern mit zwei Fragen:



**„Wie stark weicht das tatsächliche Zahlungsverhalten von den vereinbarten Zahlungszielen ab und wie groß ist die Streuung?“**

Wer die Streuung einmal quantifiziert hat, wird Durchschnittswerte nicht mehr als Steuerungsgrundlage akzeptieren.

# Quellen

---

- [1] van der Aalst, W. M. P. (2016). *Process Mining: Data Science in Action* (2. Aufl.). Springer. ISBN 978-3-662-49850-7. DOI: 10.1007/978-3-662-49851-4
- 
- [2] van der Aalst, W. M. P. et al. (2012). *Process Mining Manifesto*. In *BPM 2011, LNBP*, Bd. 99 (S. 169–194). Springer. DOI: 10.1007/978-3-642-28108-2\_19
- 
- [3] Vovk, V., Gammerman, A. & Shafer, G. (2005). *Algorithmic Learning in a Random World*. Springer. ISBN 978-0-387-00152-4. DOI: 10.1007/b106715
- 
- [4] Romano, Y., Patterson, E. & Candès, E. J. (2019). *Conformalized Quantile Regression*. *NeurIPS 2019*, 32, 3538–3548. arXiv: 1905.03222
- 
- [5] Lundberg, S. M. & Lee, S.-I. (2017). *A Unified Approach to Interpreting Model Predictions*. *NeurIPS 2017*, 30, 4766–4777. arXiv: 1705.07874
- 
- [6] Gneiting, T. & Raftery, A. E. (2007). *Strictly Proper Scoring Rules, Prediction, and Estimation*. *JASA*, 102(477), 359–378. DOI: 10.1198/016214506000001437
- 
- [7] Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M. & Bouchachia, A. (2014). *A Survey on Concept Drift Adaptation*. *ACM Comp. Surveys*, 46(4), Art. 44, 1–37. DOI: 10.1145/2523813
- 
- [8] Appel, A. P. et al. (2019). *Optimize Cash Collection: Use Machine Learning to Predicting Invoice Payment*. arXiv: 1912.10828
- 
- [9] Gleich, R., Kappes, M., Maron, C., Oehler, K. & Tschandl, M. (Hrsg.) (2024). *Planung und Forecasting neu gedacht*. Haufe. ISBN 978-3-648-18082-2
- 
- [10] REL Consulting / The Hackett Group (o. J.). *Working Capital Metrics (WAT, WADTC, WADTP)*. [thehackettgroup.com/working-capital-management](https://thehackettgroup.com/working-capital-management)

# Über die Autoren

---



## **Axel Meythaler**

Managing Director

[Axel.Meythaler@Fortlane.com](mailto:Axel.Meythaler@Fortlane.com)

+49-151-17141018



## **Pirmin Mutter**

Partner

[Pirmin.Mutter@Fortlane.com](mailto:Pirmin.Mutter@Fortlane.com)

+49-151-18236029



## **Pascal Krawczyk**

Senior Consultant

[Pascal.Krawczyk@Fortlane.com](mailto:Pascal.Krawczyk@Fortlane.com)

+49-151-18236025



KW 1 KW 2 KW 3 KW 4 KW 5 KW 6 KW 7 KW 8 KW 9 KW 10 KW 11 KW 12 KW 13

# Über Fortlane Partners

**Fortlane Partners** ist eine führende europäische Beratungsgesellschaft mit Schwerpunkt auf Strategie, M&A und Transformation. Mit einem integrierten Beratungsansatz verbindet Fortlane Partners Management-Consulting und Corporate-Finance-Expertise, um Unternehmen bei der erfolgreichen Gestaltung ihrer Zukunft zu unterstützen.

Unsere Arbeit verbindet tiefes Branchenwissen mit analytischer Schärfe und pragmatischer Umsetzungskompetenz. Wir arbeiten partnerschaftlich und ergebnisorientiert – vom ersten Konzept bis zur messbaren Wirkung.

Im Bereich Transformation und Performance begleitet Fortlane Partners Unternehmen unter anderem bei der Optimierung von Working-Capital-Prozessen, der Implementierung datengetriebener Planungsansätze und dem Einsatz von Process Mining und KI in der operativen Steuerung.