

Due Diligence im Zeitalter der KI

Von der statischen Prüfung zur lernenden Analyse

Zusammenfassung der Working Papers „Due Diligence und KI“ – Prof. Dr. Harald Meisner, MeisCon Research

Die Diskussion über KI in der Finanzanalyse konzentriert sich fast ausschließlich auf Modelle – welche sind leistungsfähiger, welche günstiger, welche erklärbarer. Dieses Working Paper zeigt, warum das der falsche Fokus ist. Es beschreibt kein Tool, sondern ein Framework für KI-gestützte Investitionsentscheidungen: theoretisch fundiert, methodisch transparent und praktisch erprobt.

Der Kern ist vielschichtig – er verbindet ökonomische Bewertungstheorie, moderne Analysemethoden und eine konkrete technische Implementierung zu einem kohärenten Gesamtbild.

1. Klassische Due Diligence: Struktur und Grenzen

Die traditionelle Due Diligence dient der systematischen Analyse von Unternehmen vor Transaktionen wie Übernahmen, Beteiligungen oder Finanzierungen. Ihr Ziel ist die Reduktion von Informationsasymmetrien, die Identifikation von Risiken und die Schaffung einer belastbaren Entscheidungsgrundlage. Der Prozess folgt drei Phasen – Vorbereitung, Analyse, Berichterstellung – und umfasst klassische Teilbereiche wie Legal, Financial, Tax, Commercial und HR.

Gerade bei Start-ups und technologiegetriebenen Unternehmen zeigt dieser Ansatz seine strukturellen Grenzen: Historische Daten fehlen, Geschäftsmodelle sind nicht-linear, und der eigentliche Unternehmenswert liegt in immateriellen Faktoren, die in keiner Bilanz auftauchen. Die klassische Logik der retrospektiven Analyse greift hier zu kurz.

2. Digitale Werttreiber und die neue Bewertungslogik

Mit der Digitalisierung verschieben sich die zentralen Werttreiber fundamental. Netzwerkeffekte, Datenbestände, Nutzerbindung und Plattformdynamiken ersetzen materielle Vermögenswerte als Hauptquellen des Unternehmenswertes. Kennzahlen wie Customer Lifetime Value, Churn-Raten, Net Dollar Retention oder aktive Nutzerzahlen gewinnen an Bedeutung – sind aber in klassischen Bewertungsmodellen kaum adäquat abgebildet.

Besonders kritisch: Viele Start-ups werden nicht über Cashflows, sondern über Multiplikatoren auf Umsatz oder Nutzerzahlen bewertet. Diese spiegeln häufig Marktstimmungen wieder statt realer Unternehmensqualität. Eine strukturierte, datengetriebene Analyse kann diese Lücke schließen, indem sie quantitative und qualitative Informationen systematisch zusammenführt und Bewertungen auf ihre tatsächlichen Werttreiber zurückführt.

3. Stand der Forschung: Methoden für eine erweiterte Due Diligence

Die zentrale These lautet: **Standardisierung vor Intelligenz**. KI entfaltet ihren Nutzen erst dann, wenn die zugrunde liegenden Daten formal eindeutig, konsistent und vergleichbar sind.

Ein bewusstes Ziel des Papers ist es, den aktuellen Stand relevanter Analysemethoden für Praktiker zugänglich zu machen. Dazu gehören KI-gestützte Prognosemodelle auf Basis maschinellen Lernens, semantische Dokumentenanalyse mittels Natural Language Processing, die intelligente Einbindung öffentlicher Datenquellen über APIs sowie simulationsbasierte Methoden wie Monte Carlo Simulationen.

Diese Methoden sind in der Forschungsliteratur etabliert – ihre systematische Zusammenführung für den Due-Diligence-Kontext und ihre Einbettung in eine praxistaugliche Pipeline ist jedoch ein originärer Beitrag des Papers.

4. Vibe Coding: Wie KI das Entwickeln verändert

Ein bewusst eingefügter Exkurs widmet sich dem sogenannten Vibe Coding – einer Form der Softwareentwicklung, bei der Code nicht mehr ausschließlich manuell geschrieben, sondern im Dialog zwischen Mensch und KI entwickelt wird. Der Anwender beschreibt Ziele und Anforderungen in natürlicher Sprache; die KI übersetzt diese in Programmcode und Softwarearchitektur.

Dieser Exkurs ist kein Ausflug in die Informatik, sondern ein methodisch relevanter Einblick: Er zeigt, wie das vorliegende Paper und die zugehörige Pipeline tatsächlich entstanden sind – nämlich in einem iterativen, dialogbasierten Prozess mit KI-Unterstützung.

Entscheidend ist dabei nicht die Technologie selbst, sondern die neue Zugänglichkeit: Ökonomen können funktionale Analysesysteme entwickeln, ohne klassische Softwareentwicklungsprozesse durchlaufen zu müssen.

5. Die Pipeline: Sechs Phasen, ein kohärentes System

Die technische Architektur besteht aus sechs sequenziell ausgeführten Jupyter-Notebooks, die vollständig lokal laufen. Datensouveränität ist dabei eine bewusste Designentscheidung: Keine vertraulichen Daten verlassen die eigene Infrastruktur.

Phase 1 extrahiert und strukturiert PDF-Businesspläne in maschinenlesbare Claim-Listen. Phase 2 analysiert diese qualitativ via lokalem Sprachmodell (SWOT, Risiken, Investment-These). Phase 3 berechnet regelbasiert KPIs aus einem standardisierten Excel-Format. Phase 4 integriert beide Perspektiven in einen konsistenten Report. Phase 6 fügt Szenarioanalyse und Monte Carlo Simulation hinzu.

Ein zentrales operatives Element ist das sogenannte **Fritz-Format** – eine standardisierte Excel-Struktur mit definierten Headerzeilen und ausschließlich berechneten Werten. Es ist das Eingangsformat für die quantitative Analyse und die operative Umsetzung des Strukturierungsgedankens: Ohne dieses Format bricht die Automatisierung an genau den Stellen zusammen, wo sie am wichtigsten wäre. Die Konvertierung realer Startup-Excels dauert 10–15 Minuten – eine bewusste

Einfügung, die danach verlässliche Automatisierung und vollständige Auditierbarkeit ermöglicht.

Die methodische Kernnovation ist Phase 5 – der Validation Layer. Hier vergleicht die Pipeline automatisch die aus dem PDF extrahierten Zahlenbehauptungen mit den berechneten Excel-KPIs. Abweichungen werden nach Toleranzklassen eingestuft (PASS / WARNING / CRITICAL) und in strukturierte Rückfragen (Request for Information, RFI) übersetzt. Der Wert liegt nicht im Glätten von Widersprüchen zwischen Businessplan-Narrativ und Finanzmodell – sondern in ihrer systematischen Sichtbarmachung.

6. Der Analyst bleibt der Entscheider

Das System liefert Orientierung, keine Entscheidungen. Der Analyst bleibt der Interpret – er definiert Gewichtungen, bewertet Kontexte und trägt die Verantwortung für das finale Urteil. Score-Ergebnisse sind heuristische Hilfsmittel, keine objektiven Wahrheiten. Diese Human-in-the-loop-Logik ist keine Einschränkung, sondern eine methodische Stärke: Transparenz und Nachvollziehbarkeit entstehen genau dort, wo Mensch und System klar getrennte Rollen haben.

Das Paper dokumentiert dabei offen die Grenzen des Systems: Sprachmodelle halluzinieren auch lokal. Musterbasierte Extraktion versagt bei unkonventionellen Formulierungen. Monte Carlo Simulationen erzeugen Szenarien, keine Prognosen. Wer diese Grenzen kennt, nutzt das System besser – und das ist die eigentliche Botschaft.

7. Token Economics: KI als Kostenfaktor denken

Ein konzeptionell eigenständiger Beitrag betrifft die Ökonomie der KI-Nutzung selbst. Tokens – die Recheneinheit moderner Sprachmodelle – werden als dritter Produktionsfaktor neben Arbeit und Kapital eingeführt. KI-gestützte Prozesse sind nicht per se effizienter, sondern nur dann, wenn der generierte Mehrwert die Tokenkosten übersteigt. Das Paper nennt ineffiziente Nutzung „Token-Burn“ und fordert ein systematisches AI Cost Management analog zum Cloud-Kostenmanagement. Für Investoren wird damit die Analyse der „AI Unit Economics“ zu einem integralen Bestandteil moderner Due-Diligence-Prozesse – gerade bei KI-basierten Geschäftsmodellen, bei denen steigende Nutzungsmengen direkt in steigende Kosten übersetzt werden.

Fazit

Das Working Paper liefert eine vielschichtige Analyse der strukturellen Defizite traditioneller Due-Diligence-Verfahren – und antwortet mit einem Framework, das ökonomische Theorie, methodische Disziplin und konkrete technische Umsetzung verbindet. Es richtet sich an Praktiker, die verstehen wollen, wie KI in der Investitionsanalyse wirklich funktioniert – jenseits von Marketingversprechen und jenseits von akademischer Abstraktion.

Für Investoren, Analysten und Berater bedeutet das: KI in der Due Diligence ist kein Selbstläufer. Wer die Datenbasis nicht strukturiert, wer Extraktion und Interpretation vermischt, wer Scores als Entscheidungersatz missversteht – der erhält Analysen, die überzeugend klingen und wenig belastbar sind.

Fehlbewertungen entstehen heute weniger durch fehlende Modelle – sondern durch unstrukturierte Daten.

Die Zukunft gehört nicht dem mächtigsten Modell, sondern dem methodisch diszipliniertesten Prozess.