

Zeitschrift für das gesamte
REDITWESEN

79. Jahrgang · 15. April 2026

8-2026

Digitaler
Sonderdruck

Pflichtblatt der Frankfurter Wertpapierbörse
Fritz Knapp Verlag · ISSN 0341-4019



KI IM BANKGESCHÄFT – DER GAMECHANGER?

Entwicklung eines ganzheitlichen AI Use Case
zur Erstellung des Gesamtbankrisikoberichtes

Svend Reuse / Tim-Oliver Engelke

Svend Reuse / Tim-Oliver Engelke

Entwicklung eines ganzheitlichen AI Use Case zur Erstellung des Gesamtbankrisikoberichtes

Artificial Intelligence (AI) oder künstliche Intelligenz (KI)¹⁾ haben seit der Einführung von Chat GPT in 2022 einen wahren Hype ausgelöst. Schon früh wurde proklamiert, dass viele Tätigkeiten sich hierdurch grundlegend verändern oder sogar überflüssig werden. Gleichwohl gilt „Amara’s Law“ weiterhin: „We tend to overestimate the effect of a technology in the short run and underestimate the effect in the long run.“²⁾ Zurzeit macht sich eine gewisse Ernüchterung breit, da die KI die an sie gesetzten sehr hohen Erwartungen (noch) nicht erfüllt. Aus Sicht der Autoren befindet sich die Technologie jedoch gerade jetzt in einem Stadium, wo die langfristigen Effekte einsetzen. Eine Vielzahl von Large-Language-Modellen (LLM) sind mittlerweile mit neuen Versionen ausgestattet, die bei richtiger Anwendung die Arbeit auch von komplexeren Tätigkeiten erheblich vereinfachen beziehungsweise beschleunigen können.

Die zentrale Forschungsfrage dieses Artikels ist folgende: Lassen sich auch die komplexen Prozesse in der Gesamtbanksteuerung durch AI so verbessern, dass die Berichterstellung von zum Beispiel dem Gesamtbankrisikobericht deutlich schneller und besser vonstatten gehen kann? Hierzu wird ein konkreter Use Case auf Basis fiktiver Daten entwickelt, der aus mehreren Prompting-Ideen in Gemini und Chat GPT besteht.³⁾

Voraussetzungen für die Nutzung von AI in der Gesamtbanksteuerung

Freie LLM-Modelle wie Gemini und Chat GPT haben den Nachteil, dass die Eingabedaten ungefiltert in das Internet gesendet werden. Vor dem Hintergrund von Datenschutz und Informationssicherheit sind sie für bankinterne Pro-

zesse somit nicht ohne Weiteres anwendbar. Folglich kommen für die Verwendung innerhalb der Banken eher gekapselte Versionen wie zum Beispiel der S-KI Pilot in der Sparkassenwelt⁴⁾ oder Geno GPT im genossenschaftlichen Sektor⁵⁾ infrage.⁶⁾ Dies hat zur Folge, dass die nutzbaren Engines in der Regel älter sind als die am Markt verfügbaren und somit die Leistungsfähigkeit beeinträchtigt ist.⁷⁾ Allerdings werden sie oft mit internen und damit qualitätsgesicherten Daten trainiert, was die Wahrscheinlichkeit des Halluzinierens reduziert.

Zudem kommt den Themen der Datenqualität, der Datenaufbereitung und der Frage der technischen Datenhaltung (Silos) eine besondere Bedeutung zu. Nur wenn die Datenqualität auf einem hohen Niveau ist und ein konsistentes und integriertes Datenbankmodell, idealerweise in Form eines Data Warehouses vorliegt⁸⁾, kann AI die volle Wirkungskraft entfalten.

Des Weiteren ist das Thema Regulatorik zu beachten. Am 12. Juli 2024 wurde die EU-KI-Richtlinie⁹⁾ veröffentlicht, welche einen einheitlichen Rechtsrahmen für KI in der EU darstellt. Die Verordnung soll die Einführung in Europa fördern, aber gleichzeitig Risiken minimieren. Sie tritt bis auf wenige Ausnahmen am 2. August 2026 in Kraft und wird auch für die Bankenlandschaft einen klareren Rahmen geben. Zudem hat die BaFin jüngst eine Orientierungshilfe veröffentlicht, in der sie den Einsatz von KI in Finanzunternehmen beschreibt und entsprechende Handlungsempfehlungen zum Einsatz von KI gibt. Besonders empfeh-

Abbildung 1: Wertung der Einsatzmöglichkeiten von AI

Gesamtbankrisikobericht nach MaRisk: Sinnhaftigkeit von AI Use Cases			
		Analyse aggregierter Daten	Analyse Einzeldatensätze
Risiken	Adressrisiko	+	+++
	Marktpreisrisiko / Zinsrisiko	++	++
	Liquiditätsrisiko	+	+++
	Operationelles Risiko	+	++
ICAAP	Ökonomische Risikotragfähigkeit	+++	+
	Normative Sicht	+++	+
	Stresstests & adverse Szenarien	+++	+
Übergreifend	ESG am Beispiel ESG Score	+	+++
	Sonstige Berichtspflichten	+++	+
	Gesamtfazit	+++	~

Quelle: T.-O. Engelke, S. Reuse (auf Basis eigener Einschätzung)

lenswert ist die Fallstudie zum Ende des Papiers, welche anschaulich aufzeigt, wie der Einsatz von KI in Banken gelingen kann.¹⁰⁾ Regulierung ist hier aus Sicht der Autoren positiv zu sehen, da die Risiken aus dem falschen Einsatz von KI hoch sind. Die EU hat hier eine Art USP (Unique Selling Proposition), da sie beim Thema Regulierung weit vorn ist. Dies bietet mehr Chancen als Risiken.

Zu guter Letzt ist die Kompetenz der handelnden Mitarbeiter eine wichtige Komponente. Durch die disruptive Technologie rücken viele Fähigkeiten wie Programmieren, Excel-Kenntnisse und Analysefähigkeiten in den Hintergrund. Dies kann zu Unsicherheit bei den Betroffenen führen, da sie in der neuen Technologie noch nicht so sicher sind wie in den bisherigen Systemen. Hier gilt es, Ängste zu nehmen und Kompetenzen aufzubauen. Denn die Arbeitsplätze werden nicht überflüssig, sondern anders ausgestaltet. Prozesse werden schneller und die finale Verantwortung muss immer beim Menschen liegen, da dieser die Ergebnisse der KI plausibilisieren können muss, um Fehler aufzudecken. Letztlich gilt: „Spezialisten werden nie durch KI ersetzt, aber durch Spezialisten, die KI nutzen.“¹¹⁾

Der Gesamtbankrisikobericht – Zuordnung von Teil-Use Cases

Ein konkreter Use Case ist die vierteljährliche Erstellung des Gesamtbankrisikoberichtes nach MaRisk¹²⁾, BT 3.1. Dieser umfasst neben allen wesentlichen Risikoarten nach AT 2.2, BTR 1-5 auch die Risikotragfähigkeit nach AT 4.1, Stresstests nach AT 4.3.3 und Aspekte zu ESG nach BT 3.2.

Hierbei wird auf unterschiedlichen Aggregationsebenen berichtet. Während ökonomische Risikotragfähigkeit, normative Sicht und Stresstests eher auf Basis von aggregierten Daten analysiert werden, gehen die Analysen bei den vier wesentlichen Risiken, vor allem beim Thema Adress- und Liquiditätssteuerung, eher auf Einzeldatensätze. Abbildung 1 verdeutlicht den Einsatz

von KI bei der Erstellung des Gesamtbankrisikoberichtes und wertet ein, wie KI am besten Anwendung finden kann.

Für den Einsatz von KI ist es wichtig, dass diese Einzeldatensätze sauber aufbereitet sind und einem einheitlichen Datenmodell folgen. Hierfür bietet sich eine Veredelung mittels Access oder Excel Power Query an.

Modellierung eines ganzheitlichen Use Cases für den Risikobericht

Im Folgenden werden aus der obigen Matrix exemplarisch zwei Fallbeispiele von den zehn möglichen Teil-Use Cases aufgebaut. Zum einen wird die ökonomische Risikotragfähigkeit als Beispiel für eine Wertung auf Basis aggregierter Daten modelliert.

Zum anderen wird die Analyse des Liquiditätsrisikos auf Basis von Einzeldatensätzen durchgeführt. Hierbei werden zwei verschiedene Engines eingesetzt. Für die aggregierte Sichtweise wird Chat GPT verwendet, für die Analyse der Einzeldatensätze Gemini mit Python.¹³⁾

Teil-Use Case 1: Ökonomische Risikotragfähigkeit

Die Aufgabenstellung besteht in der Analyse der wesentlichen Eckdaten der Risikotragfähigkeit über acht Quartale. Neben den typischen Risikotragfähigkeits- und Limitwerten werden jedoch auch Eckdaten einer fiktiven Bank im Zeitablauf angegeben. Diese muss die KI als Erläuterung für die Entwicklungen interpretieren.

Hierzu wurde ein Prompt erstellt, der der KI genau beschreibt, was zu tun ist. Dieser ist wie folgt aufgebaut:

- Definition der Rolle als Leiter Risikotragfähigkeit einer Bank.
- Detaillierte Beschreibung der Datenbasis „Rohdaten_RTF_xlsx“: 18 Zeilen mit Eckdaten, Risiken, Limiten und Zu-



Foto: Ines Walter Unternehmensfotografie



Prof. Dr. Svend Reuse

Stellvertretender Vorsitzender des Vorstands, Kreissparkasse Düsseldorf; Honorarprofessor an der FOM Hochschule für Oekonomie und Management



Foto: privat



Tim-Oliver Engelke

Bereichsleiter Gesamtbanksteuerung & Leiter der Risikocontrollingfunktion, Kreissparkasse Düsseldorf

Das Thema KI ist omnipräsent. Große Umwälzungen werden erhofft oder befürchtet – je nach Blickwinkel. Doch meist werden nur allgemeine Chancen und Risiken diskutiert. Tim-Oliver Engelke und Svend Reuse haben ein konkretes und auch diffiziles Anwendungsszenario aus dem Alltag der Banksteuerung entwickelt und dieses auch gleich im Detail geprüft. Sie kommen zu dem Ergebnis, dass KI die Arbeit erheblich erleichtern kann, aber der Mensch immer eine finale Qualitätskontrolle durchführen muss und somit nicht überflüssig wird. (Red.)

satzinformationen wie zum Beispiel Kreditvolumen, durchschnittliche Ratingnote, Liquidität für die acht Quartale 31. März 2024 – 31. Dezember 2025.

- Aufgaben: Erstellung eines Management Dashboards, Entwicklung der Risikotragfähigkeit und des Gesamtlimits, Detailanalyse der Risikowerte und Limite, Zusammenfassung der Gesamtrisikolage.

Der detaillierte Prompt findet sich in Abbildung 2, die Rohdaten zeigt Abbildung 3.

Im nächsten Schritt gilt es, die Ergebnisse zu präsentieren. Abbildung 4 zeigt

Abbildung 2: Teil-Use Case 1 – Detaillierter Prompt

1. Rolle

Du bist Leiter Risikocontrolling einer Bank und hast Daten zur Risikotragfähigkeit vorliegen, die Du für die Geschäftsleitung der Bank auswerten musst.

2. Datenbasis

Du erhältst beiliegende Datei Rohdaten_RTF.xlsx. Diese ist wie folgt aufgebaut: Die Spalten beinhalten Daten zu den einzelnen Quartalen, beginnend mit dem 31.03.2024 und endend mit dem 31.12.2025. In den Zeilen findest Du folgende Werte:

1. Kreditvolumen in Mill. €: Hierbei handelt es sich um das Kreditvolumen der Bank.
2. Besichertes Kreditvolumen in Mill. €: Dieses Teilvolumen des Kreditgeschäftes gilt als risikolos und beeinflusst den Risikowert nicht.
3. Durchschnittliche Ratingnote: Diese ist auf einer Skala von 1 bis 10 ermittelt, wobei 1 die beste und 10 die schlechteste Note darstellt.
4. Liquidität auf der Aktivseite in Mill. €: Hierbei handelt es sich um die sofort verfügbare Liquidität der Bank.
5. Aktienbestand in Mill. €: Hierbei handelt es sich um einen breit gestreuten Eurostoxx-Bestand.
6. Gebuchte Schadensfälle in Mill. €: Dies sind Schäden, die aufgrund eines Diebstahls zustande kamen.
7. Bilanzielles Eigenkapital in Mill. €: Hierbei handelt es sich um das Gesamtkapital der Bank, welches gleichzeitig das Kernkapital darstellt.
8. Risikotragfähigkeit in Mill. €: Dies ist der Gesamtbankbarwert der Bank.
9. Gesamtbanklimit in Mill. €: Hierbei handelt es sich um die Summe aller Unterlimate der Nr. 10. bis 13.
10. darunter: Limit Adressrisiko in Mill. €
11. darunter: Limit Marktpreisrisiko und Zinsrisiko in Mill. €
12. darunter: Limit Liquiditätsrisiko in Mill. €
13. darunter: Limit Operationelles Risiko in Mill. €
14. Gesamtrisiko in Mill. €: Hierbei handelt es sich um die Summe aller Risiken der Nr. 15. bis 18.
15. darunter: Risiko Adressrisiko in Mill. €
16. darunter: Risiko Marktpreisrisiko und Zinsrisiko in Mill. €
17. darunter: Risiko Liquiditätsrisiko in Mill. €
18. darunter: Risiko Operationelles Risiko in Mill. €

3. Aufgaben

Du hast mehrere Aufgaben, die Du bitte auch optisch wie folgt strukturierst und abgrenzt:

1. Erstelle ein Management Dashboard, welches die wichtigsten Kennzahlen im Zeitablauf darstellt.
2. Analysiere die Entwicklung von Risikotragfähigkeit (Nr. 8), Eigenkapital (Nr. 7) und Gesamtbanklimit (Nr. 9) im Zeitablauf und bewerte diese Entwicklung. Bitte fasse dies in maximal 5 Sätzen zusammen.
3. Analysiere die Entwicklung der Limite und Risikowerte. Als Unterstützung hierzu dienen Dir die Nr. 1 bis 6. Ordne diese den Risikoarten zu und begründe, wieso sich die Risikowerte so entwickelt haben. Beschränke Dich auf maximal 10 Sätze.
4. Fasse die Gesamtrisikolage der Bank zusammen, indem Du den Stichtag 31.12.2025 mit dem 31.03.2024 vergleichst. Hierbei sollte der Umfang maximal 5 Sätze betragen.

Quelle: Darstellung T.-O. Engelke, S. Reuse

das Management Dashboard nebst Erläuterungen und Abbildung 5 die verbalen Analysen.

Zu erkennen ist, dass das Dashboard anschaulich formatiert ist und die wesentlichen Kennzahlen enthält – dies ist vor allem deshalb bemerkenswert als dass der Prompt keine konkreten Anweisungen zur Auswahl der Kennzahlen enthält. Auch die verbalen Ausführungen gelingen gut. Die Engine hat die Zusammenhänge mehrheitlich richtig erkannt und interpretiert. Die versteckt eingebaute Verknappung von Kapital wird erkannt und es wird eine klare Positionsbeschreibung der Bank formuliert, wie exemplarisch folgender Auszug zeigt: „In Summe verbessert sich die nominale Limit-/Kapital-Ausstattung, gleichzeitig deutet der fallende Gesamtbankbarwert (RTF) auf eine sinkende ökonomische Tragfä-

higkeit hin. Aus Managementsicht ist die Limitanhebung daher nur dann nachhaltig, wenn die Ursachen der RTF-Erosion adressiert und mit der Risikoentwicklung konsistent gesteuert werden.“

Dies zeigt, dass die KI in der Lage ist, auch komplexe Zusammenhänge auf aggregierter Ebene adäquat zu analysieren und zu interpretieren, auch wenn die Ergebnisse noch nicht perfekt und vom Controller final zu überprüfen sind.

Teil-Use Case 2: Liquiditätsrisiko und ILAAP

Die geldpolitische Wende der EZB hat den Wettbewerb um Kundeneinlagen grundlegend verschärft. Laut Barkow Consulting konnten Direktbanken und

Neobanken seither systematisch Marktanteile gewinnen.¹⁴⁾ Eine PwC-Langzeitanalyse aus 2024 belegt, dass diese Institute ihren Einlagenmarktanteil über zwei Jahrzehnte um mehr als 12 Prozentpunkte ausbauen.¹⁵⁾ Parallel schichten Kunden klassische Sichteinlagen in höher verzinsliche Produkte um – ein Risiko, das die BaFin in ihrem Fokusrisikobericht 2024 explizit adressiert.¹⁶⁾ In diesem Umfeld gewinnt ein proaktives Einlagenmonitoring an Bedeutung und angesichts der Datenvolumina bieten Large Language Models (LLMs) hier besondere Chancen.

Stufe 0 – Datenbasis und Methodik: Zur Evaluierung wurde mithilfe von Google Gemini 3.1 (Pro) ein synthetisches Musterportfolio auf Einzelkontenebene generiert: 100000 Kunden, 225410 Konten, ein Ausgangsvolumen von 3,5 Milliarden Euro, bestehend aus unverzinsten Sichteinlagen, Tagesgeldern



Abbildung 3: Teil-Use Case 1 – Rohdaten

	31.03.2024	30.06.2024	30.09.2024	31.12.2024	31.03.2025	30.06.2025	30.09.2025	31.12.2025
1. Kreditvolumen in Mill. €	1200	1220	1250	1240	1260	1300	1350	1400
2. Besichertes Kreditvolumen in Mill. €	600	610	615	620	625	630	630	635
3. Durchschnittliche Ratingnote	5,5	5,6	5,5	5,7	5,8	5,9	6,1	6,3
4. Liquidität auf der Aktivseite in Mill. €	200	210	220	230	240	260	280	290
5. Aktienbestand in Mill. €	50	50	60	70	80	80	90	100
6. Gebuchte Schadensfälle in Mill. €	1	1	1	1	1	1	6	6
7. Bilanzielles Eigenkapital in Mill. €	250	250	250	260	260	260	260	270
8. Risikotragfähigkeit in Mill. €	325	320	315	310	305	300	295	290
9. Gesamtkreditlimit in Mill. €	200	200	200	200	210	220	230	240
10. darunter: Limit Adressrisiko in Mill. €	60	60	60	60	60	70	70	80
11. darunter: Limit Marktpreisrisiko und Zinsrisiko in Mill. €	70	70	70	70	80	80	80	80
12. darunter: Limit Liquiditätsrisiko in Mill. €	40	40	40	40	40	40	40	40
13. darunter: Limit Operationelles Risiko in Mill. €	30	30	30	30	30	30	40	40
14. Gesamtrisiko in Mill. €	165	166	168	168	179	186	198	204
15. darunter: Risiko Adressrisiko in Mill. €	50	52	55	56	57	65	68	75
16. darunter: Risiko Marktpreisrisiko und Zinsrisiko in Mill. €	60	61	62	63	75	76	77	78
17. darunter: Risiko Liquiditätsrisiko in Mill. €	30	28	26	24	22	20	18	16
18. darunter: Risiko Operationelles Risiko in Mill. €	25	25	25	25	25	25	35	35

Quelle: Darstellung T.-O. Engelke, S. Reuse

und Sparbriefen, aufgeteilt auf Privat-, Geschäfts- und Kommunkunden. Das Volumen sinkt im Jahresverlauf auf 3,35 Milliarden Euro.

Der methodische Kern basiert auf strukturiertem Prompt Engineering: Fünf spezifische Anweisungsblöcke induzieren deterministisches Modellverhalten. Dazu zählen explizite Instruktionen zur Datenbereinigung – Substitution fehlender Werte, Eliminierung von Leerzeichen in Textfeldern –, um technische Fehler zu vermeiden und reproduzierbare Ergebnisse zu gewährleisten. Je Prompt und Anforderung, welche an die KI gestellt wurde, nahm die Komplexität der Anfragen zu.

Stufe 1 – Datenintegrität: Das Modell wurde angewiesen, eine hierarchische

Kreuztabelle der Bestandsentwicklung zu erstellen – primär aggregiert nach Produktkategorie (Giro, Tagesgeld, Sparbrief 1J–3J), sekundär nach Kundensegment, inklusive Zwischensummen je Produkt und Gesamtergebnis-

Zeile. Allein basierend auf den Rohdaten und dem Prompt replizierte die KI die definierten Volumina fehlerfrei und validierte damit ihre Eignung zur Verarbeitung von Massendaten. Hinsichtlich einer sauberen Datenstrecke ist es demnach möglich, Rohdaten direkt über eine KI in Pivots und Dash-

boards verarbeiten zu lassen. Dies zeigt Abbildung 6.¹⁷⁾

Der Prompt definierte dabei sämtliche Strukturparameter explizit: relevante Spalten, zweistufige Zeilenhierarchie,

„Arbeitsplätze werden nicht überflüssig, sondern anders ausgestaltet.“

Subtotal-Logik und Ausgabeformat. Das Modell generierte daraufhin eigenständig einen Python-Code und führte diesen aus. Entscheidend für die Reproduzierbarkeit war die Rollenzuweisung als Data Analyst sowie die präzise Formatvorgabe mit Tausendertrennzeichen. Das Ergebnis entsprach exakt einer manuell

Abbildung 4: Teil-Use Case 1 – Management Dashboard

1) Management Dashboard (Zeitablauf der wichtigsten Kennzahlen)

Ich habe auf Basis der Datei Rohdaten_RTF.xlsx ein Excel-Management-Dashboard erstellt (inkl. KPI-Kacheln, Zeitreihenübersicht und Charts sowie einem Analyse-Tab mit abgeleiteten Steuerungskennzahlen).

Management Dashboard – Risikotragfähigkeit (RTF)								
Zeitreihe: 31.03.2024 bis 31.12.2025 Alle Zahlen in Mill. €								
Risikotragfähigkeit (RTF)	290,0		Gesamtrisiko		204,0		Risikopuffer (RTF - Risiko)	
	-35,0 ggü 31.03.2024 -5,0 ggü VQ				+39,0 ggü 31.03.2024 +6,0 ggü VQ		-74,0 ggü 31.03.2024 -11,0 ggü VQ	
Eigenkapital	270,0		Gesamtbanklimit		240,0		RTF-Auslastung (Risiko/RTF)	
	+20,0 ggü 31.03.2024 +10,0 ggü VQ				+40,0 ggü 31.03.2024 +10,0 ggü VQ		70,3%	
							+19,6% ggü 31.03.2024 +3,2% ggü VQ	

Zeitverlauf – zentrale Steuerungsgrößen								
Kennzahl	31.03.2024	30.06.2024	30.09.2024	31.12.2024	31.03.2025	30.06.2025	30.09.2025	31.12.2025
Risikotragfähigkeit (RTF)	325,0	320,0	315,0	310,0	305,0	300,0	295,0	290,0
Gesamtrisiko	165,0	166,0	168,0	168,0	179,0	186,0	198,0	204,0
Risikopuffer (RTF - Risiko)	160,0	154,0	147,0	142,0	126,0	114,0	97,0	86,0
Gesamtbanklimit	200,0	200,0	200,0	200,0	210,0	220,0	230,0	240,0
Limit-Auslastung (Risiko/Limit)	82,5%	83,0%	84,0%	84,0%	85,2%	84,5%	86,1%	85,0%
RTF-Auslastung (Risiko/RTF)	50,8%	51,9%	53,3%	54,2%	58,7%	62,0%	67,1%	70,3%

Aufbau der Datei: hier nur Reiter „Dashboard“ dargestellt

– Dashboard: KPI-Kacheln (aktueller Stand 31.12.2025 inkl. Δ ggü. 31.03.2024 & ggü. Vorquartal), Tabelle „zentrale Steuerungsgrößen“, Charts (RTF/Risiko/Puffer; EK/Limit; Risiko-Stack; Limit-Stack)

– Analyse: Zeitreihe + abgeleitete Kennzahlen (Risikopuffer, Auslastungen, unbesichertes Kreditvolumen)

– Daten: unveränderte Rohdaten

Quelle: Darstellung T.-O. Engelke, S. Reuse; Inhalte entnommen aus Chat GPT (2026), Version 5.4 Thinking. Abbildung mit ergänzendem Prompt auf Excel 2021 formatiert.

erstellten Excel-Pivot-Tabelle – ohne dass ein einziger Handgriff im Datensatz erforderlich war. Dies belegt: Strukturierter Prompt Engineering überträgt fachli-

gen sowie Zinsgutschriften auszuschließen. Für jede Kombination aus Quartal, Produkt und Richtung wurden die 15 größten Einzelbewegungen nach Delta-

Modell explizit angewiesen, Zahlungsströme je Fremdbank und Quartal separat zu aggregieren und über den Banknamen zu konsolidieren. Die Migrationsmatrix zeigt eine klare Dominanz der Direktbanken: Sie vereinen –43,0 und –45,5 Millionen Euro Nettosaldo (rund 80 Prozent des Gesamtabflusses) bei beschleunigender Dynamik (Outflow-Faktor Q4 vs. Q2: 3,2x). Sparkassen und Genobanken verzeichnen stabile Abflüsse ohne Eskalationsmuster – eine direkte Grundlage für wettbewerbspezifische Konditionsanpassungen. Auch hier ist die KI in der Lage, basierend auf unbearbeiteten Rohdaten strukturelle Muster zu erkennen. Im Sinne eines Frühwarnsystems können demnach zum Beispiel Anlässe zum Pricing identifiziert werden, wenn Kunden konzentriert zu einem Wettbewerber abwandern. Abbildung 8 zeigt die Ergebnisse der Zahlungsstromanalyse zu anderen Banken.

„Der methodische Kern basiert auf strukturiertem Prompt Engineering.“

che Logik zuverlässig auf das Modell und macht KI-gestützte Auswertungen nicht nur schneller, sondern auch nachvollziehbar und prüffähig.

Stufe 2 – Top-Bewegungen: Beim zweiten Prompt sollte die KI die größten In- und Outflows identifizieren. Der Prompt instruierte das Modell, die Spalte „Bewegung_Art_QX“ streng nach „Outflow (extern)“ beziehungsweise „Inflow (extern)“ zu filtern und interne Umbuchun-

wert sortiert ausgegeben – automatisierte Ranglisten, die dem Treasury eine unmittelbare, einzelkundenbezogene Reaktion ermöglichen. Die KI ist demnach in der Lage, allein basierend auf den Rohdaten Muster und Konzentrationen zu erkennen. Abbildung 7 zeigt die Modellierung der größten Zu- und Abflüsse.

Stufe 3 – Gegenbanken-Matrix: Da ein Kunde quartalsweise zu verschiedenen Instituten transferieren kann, wurde das



Abbildung 5: Teil-Use Case 1 – Verbale Analyse

2) Entwicklung von RTF (Nr. 8), Eigenkapital (Nr. 7) und Gesamtbanklimit (Nr. 9) – Bewertung (max. 5 Sätze)

Die Risikotragfähigkeit (RTF) sinkt von 325,0 Mill. € (31.03.2024) auf 290,0 Mill. € (31.12.2025), also um 35,0 Mill. € bzw. - 10,8 %. Das bilanzielle Eigenkapital steigt im gleichen Zeitraum moderat von 250,0 auf 270,0 Mill. € (+ 20,0 Mill. €, + 8,0 %) und wirkt damit grundsätzlich stabilisierend. Das Gesamtbanklimit wird sukzessive von 200,0 auf 240,0 Mill. € angehoben (+ 40,0 Mill. €, + 20,0 %), insbesondere im Verlauf von 2025. In Summe verbessert sich die nominale Limit-/Kapital-Ausstattung, gleichzeitig deutet der fallende Gesamtbankbarwert (RTF) auf eine sinkende ökonomische Tragfähigkeit hin. Aus Managementsicht ist die Limitanhebung daher nur dann nachhaltig, wenn die Ursachen der RTF-Erosion adressiert und mit der Risikoentwicklung konsistent gesteuert werden.

3) Entwicklung der Limite & Risikowerte – Treiberzuordnung (Nr. 1–6) und Begründung (max. 10 Sätze)

Adressrisiko wird maßgeblich durch das unbesicherte Kreditvolumen und die Bonität (Ø Ratingnote) getrieben. Das unbesicherte Kreditvolumen steigt von 600 auf 765 Mill. € und die Ratingnote verschlechtert sich von 5,5 auf 6,3, was den Anstieg des Adressrisikos von 50 auf 75 Mill. € plausibel erklärt. Das Limit Adressrisiko wird zwar von 60 auf 80 Mill. € erhöht, dennoch steigt die Auslastung von 83 % auf rund 94 %. Marktpreis- und Zinsrisiko ordne ich primär dem Aktienbestand (Eurostoxx-Exposure) zu, der von 50 auf 100 Mill. € wächst. Entsprechend steigt das Markt-/Zinsrisiko von 60 auf 78 Mill. €; bei einem nur auf 80 Mill. € angehobenen Limit liegt die Auslastung am Ende bei ca. 98 % (nahe am Limit). Liquiditätsrisiko hängt hier direkt mit der sofort verfügbaren Aktiv-Liquidität zusammen; diese steigt von 200 auf 290 Mill. €, während das Liquiditätsrisiko von 30 auf 16 Mill. € zurückgeht. Bei konstantem Liquiditätslimit von 40 Mill. € verbessert sich die Auslastung deutlich (von 75 % auf 40 %). Operationelles Risiko ist anhand der gebuchten Schadensfälle (Diebstahl) erklärbar: Ab 30.09.2025 steigen die Schäden von 1 auf 6 Mill. € und das OpRisk springt von 25 auf 35 Mill. €. Parallel wird das OpRisk-Limit von 30 auf 40 Mill. € erhöht, die Auslastung liegt zum Ende dennoch bei 88 % und sollte eng überwacht werden.

4) Gesamtrisikolage: Vergleich 31.12.2025 vs. 31.03.2024 (max. 5 Sätze)

Zum 31.12.2025 liegt das Gesamtrisiko bei 204,0 Mill. € gegenüber 165,0 Mill. € am 31.03.2024 (+ 39,0 Mill. €, + 23,6 %), während die RTF gleichzeitig von 325,0 auf 290,0 Mill. € sinkt. Der Risikopuffer (RTF – Gesamtrisiko) reduziert sich dadurch von 160,0 auf 86,0 Mill. € (- 74,0 Mill. €, - 46 %). Die Gesamtlimit-Auslastung bleibt hoch und steigt leicht von 82,5 % auf 85,0 %, wobei insbesondere Markt-/Zins- (≈ 98 %) und Adressrisiko (≈ 94 %) die Engpässe bilden. Positiv ist der Aufbau von Eigenkapital (250,0 → 270,0 Mill. €) sowie der deutliche Rückgang des Liquiditätsrisikos, was die Risikostruktur etwas stabilisiert. In Summe ist die Bank zum Ende des Horizonts zwar weiterhin innerhalb der Limite, aber mit spürbar geringerer ökonomischer Risikotragreserve und damit erhöhter Steuerungs- und Handlungsnotwendigkeit.

Quelle: Darstellung T.-O. Engelke, S. Reuse; Inhalte entnommen aus Chat GPT (2026), Version 5.4 Thinking

Stufe 4 – Churn-Scoring: In dieser Stufe konnte eine besondere zusätzliche Entwicklung festgestellt werden. Basierend auf den bisherigen Prompts und der Zielrichtung schlug die KI selbst vor, von einem eher vergangenheitsorientierten in ein zukunftsorientiertes Modell zu wechseln. Dabei wurde konkret der Vorschlag eines „Churn-Scores“ unterbreitet. Ein Churn-Score (Abwanderungswahrscheinlichkeit) ist ein aus Daten berechneter Wert, der angibt, wie wahrscheinlich es ist, dass ein Kunde ein Produkt oder eine Dienstleistung kündigt beziehungsweise nicht mehr nutzt.

Das Modell aggregierte Kontodaten auf Kundenebene und wendete ein fünfdimensionales Regelwerk an: Kundenprofil, Volumen- und Zinsrisiko, Produktmix, Abflusshistorie und Direktbank-Affinität. Hohe Sichteinlagen ohne verzinsliche Gegenprodukte galten als Renditedefizit; Sparbrief-Bindungen wirkten risikomindernd. Den Maximalscore von 11,5 Punkten erreichten 2 600 Kunden – ausnahmslos Geschäftskunden mit Einzelgirokonto, Direktbank-Abfluss in zwei

aufeinanderfolgenden Quartalen und fehlendem Anlageprodukt. Das Ergebnis ist eine priorisierte Fokus-Liste für risiko-adäquate Vertriebsressourcen-Allokation, wie Abbildung 9 zeigt.

Stufe 5 – Deckungsbeitrags-Impact: In Stufe 5 sollte analysiert werden, welcher Verlust des Deckungsbeitrages mit den identifizierten Abflüssen der Kundeneinlagen einhergeht. Bezüglich der Methodik wurde der KI die PDF bezüglich der Bundesbank-Ausfüllhinweise zum LSI-Stresstest gegeben.¹⁸⁾

Die KI war in der Lage das von der Bundesbank im LSI-Stresstest empfohlene Verfahren zur Ableitung des Konditionen- und Strukturbeitrages zu identifizieren und auf die Rohdaten anzuwenden. Die Parameter wurden vom End-User festgelegt: Referenzzins 2,02

Prozent, Swapsatz 2,68 Prozent, Ablauf-fiktion Sichteinlagen 20/80 Prozent, Tagesgeld je 50 Prozent. Je externem Abfluss ermittelte die KI automatisiert den entgangenen Konditionenbeitrag und

„Schlussendlich hat immer ein Mensch die Verantwortung für die Ergebnisse, nicht die KI.“

den Strukturbeitrag aus der Fristentransformation. Für Q4 resultierte im Beispiel ein Deckungsbeitragsverlust von 1,29 Millionen Euro per annum bei 64,2 Millionen Euro Abflussvolumen. Derartige automatisierte Ermittlungsverfahren können im Pricing demnach auch für Preisobergrenzen und Sonderkonditionen genutzt werden. Abbildung 10 visualisiert diese Ergebnisse.

Der Prompt war in sechs Schritte gegliedert und wies der KI die Rolle eines Senior Controllers zu. Er definierte präzise Filterregeln, legte die Berechnungsformeln für Konditionenmarge und Struk-

Abbildung 6: Teil-Use Case 2 – Pivot-Portfolio Aggregation (Validierung)

Prompt an die KI zur Pivot-Tabellen-Erstellung

Du agierst als Data Analyst. Erstelle eine klassische Pivot-Tabelle zur Bestandsentwicklung aus den Rohdaten (225410 Konten).

1. Relevante Spalten

Gruppierungs-Spalten: ‚Produkt‘ und ‚Kundengruppe‘

Werte-Spalten (Bestände): ‚30.03.2025‘, ‚30.06.2025‘, ‚30.09.2025‘, ‚31.12.2025‘

2. Pivot-Logik

1. Zeilen (Hierarchie): Ebene 1 = Produkt | Ebene 2 = Kundengruppe (Geschäftlich, Kommunal, Privat).
2. Werte: Summe der vier Bestandsspalten je Kombination aus Produkt und Kundengruppe.
3. Zwischensummen (Subtotals): Je Produkt eine eigene Zeile (z.B. ‚Giro Gesamt‘).
4. Gesamtsumme (Grand Total): Zeile ‚Gesamtergebnis‘ ganz unten.

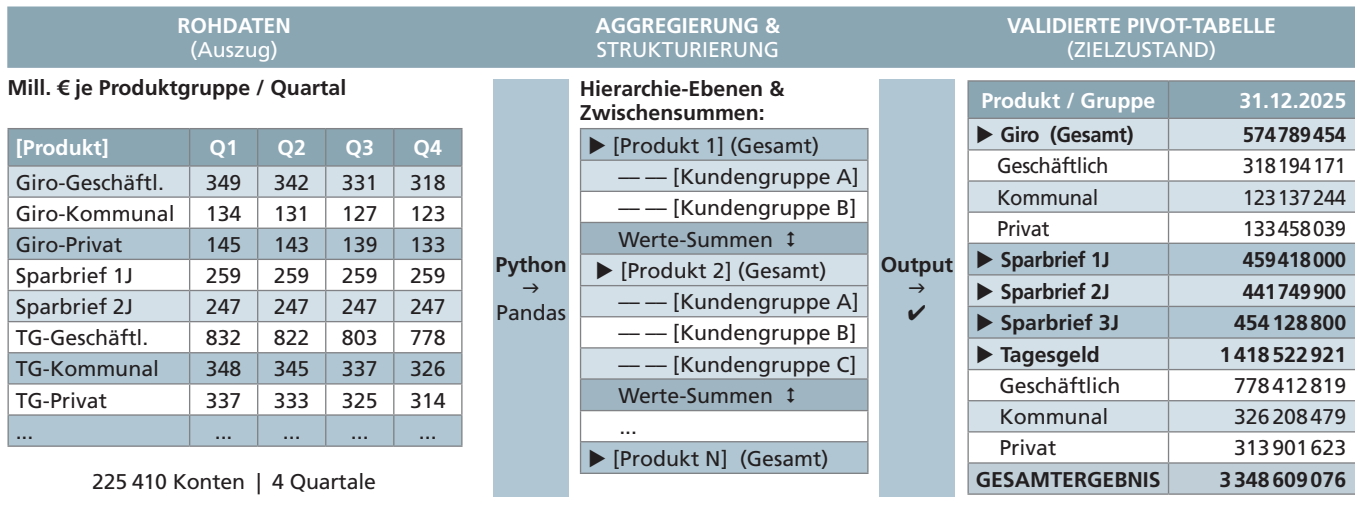
3. Gewünschtes Ausgabeformat

Ganzzahlen mit Tausendertrennzeichen (z.B. 1.517.463.169). Strukturell so:

Produkt / Gruppe	30.03.2025	30.06.2025	30.09.2025	31.12.2025
▶ Giro (Gesamt)
Geschäftlich
Kommunal
Privat
▶ Sparbrief 1J (Gesamt)
Gesamtergebnis	3 499 996 100

Bitte lies die Daten ein, führe den Python-Code aus und zeige mir das Ergebnis.

Analyseprozess: Rohdaten → Aggregation & Strukturierung → Validierte Pivot-Tabelle



Quelle: Darstellung T.-O. Engelke, S. Reuse; auf Basis der Ergebnisse aus Google Gemini 3.1 Pro (2026)

turmarge je Kontozeile fest und spezifizierte die Ausgabe als Ranking nach Deckungsbeitragsverlust. Damit wird erstmals auf Einzelkontenebene sichtbar, welchen konkreten GuV-Schaden ein Einlagenabfluss tatsächlich verursacht – aufgeschlüsselt nach Konditionenbeitrag aus dem Kundenzins und Strukturbeitrag aus der Fristentransformation.

Klassische Bestandsauswertungen liefern diese Kausalität nur bedingt; sie zeigen Volumenveränderungen, aber nicht deren Ertragswirkung. Durch den

strukturierten Prompt überträgt der Analyst seine fachliche Bewertungslogik vollständig auf das Modell – reproduzierbar und ohne manuelle Zwischenschritte. Derartige automatisierte Ermittlungsverfahren können im Pricing demnach auch für Preisobergrenzen und Sonderkonditionen genutzt werden.

Die Analysen wurden dadurch gehärtet, dass sie zusätzlich mit Chat GPT und Claude wiederholt wurden. Bemerkenswert ist, dass alle fünf Kernanalysen mit identi-

schon Ergebnissen in allen drei Engines reproduzierbar waren. Die Evaluierung belegt: Deterministisch „promptierte“ LLMs sind in der Lage, komplexe Datenaggregationen und finanzmathematische Kalkulationen auf Rohdatenebene fehlerfrei durchzuführen. Für Risikocontrolling und Treasury resultieren daraus wesentliche Mehrwerte: Transparenz über Migrationsströme unterstützt die LCR-Steuerung, die margenbasierte Ertragsanalyse schützt den Zinsüberschuss. Regulatorische Methodik und operatives Kundenmanagement werden so effizient



Abbildung 7: Teil-Use Case 2: Externe Top-Bewegungen

Prompt an die KI – Analyse größter Ein- und Abflüsse

Identifiziere die größten externen Kapitalbewegungen. Interne Umbuchungen und Zinsgutschriften sind vollständig auszuschließen.

1. Filterregeln (streng)

Bewegung_Art_QX exakt == „Outflow (extern)“ bzw. „Inflow (extern)“ – alle anderen Bewegungsarten ausschließen.

Produkt-Filter: nur ‚Giro‘ und ‚Tagesgeld‘

2. Kombinationen & Sortierung

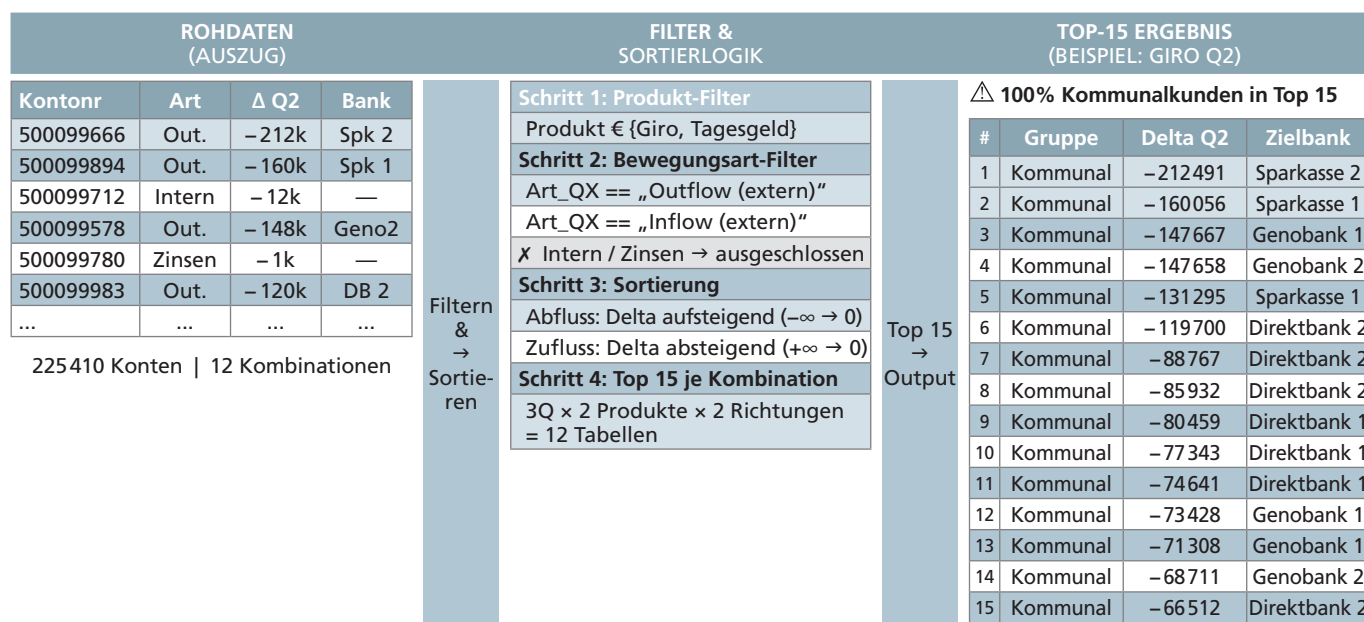
12 Tabellen: 3 Quartale (Q2/Q3/Q4) × 2 Produkte × 2 Richtungen (Outflow/Inflow)

Abflüsse: Delta aufsteigend | **Zuflüsse:** Delta absteigend | Top 15 je Kombination

3. Ausgabe (Beispielauszug: Top 3 externe Abflüsse Giro Q2)

ID	Gruppe	Kontonr	Prod.	Zins	Bst.31.03.	Bst.30.06.	Delta Q2	Art Q2	Bank Q2
1099666	Kommunal	500099666	Giro	0,0%	2.204.017	1.991.526	-212.491	Outflow	Sparkasse 2
1099894	Kommunal	500099894	Giro	0,0%	2.652.505	2.492.449	-160.056	Outflow	Sparkasse 1
1099712	Kommunal	500099712	Giro	0,0%	2.273.361	2.125.694	-147.667	Outflow	Genobank 1

Analyseprozess: Rohdaten → Filter & Sortierlogik → Top-15 Ergebnis (Beispiel: Giro Q2)



Quelle: T.-O. Engelke, S. Reuse; auf Basis der Ergebnisse aus Google Gemini 3.1 Pro (2026)

verzahnt – datengetrieben und mit minimalem manuellem Aufwand.

Blick in die Zukunft

Als Fazit lässt sich festhalten, dass die Forschungsfrage eindeutig mit „Ja“ beantwortet werden kann. Auch komplexe Aufgaben wie die Erstellung des Risikoberichtes sind mit KI möglich und bei der richtigen Modellierung der Prompts lassen sich gute Ergebnisse erzielen, die die Arbeit schneller und besser werden lässt.

Die Erfolgsfaktoren für einen funktionierenden ganzheitlichen Use Case lassen sich wie folgt zusammenfassen:

– Auswahl der richtigen Engine, wenn die Wahl zwischen mehreren Engines besteht. Manche sind in Bezug auf Analysen stärker, manche erzeugen bessere Excel-Dateien oder Bilder.

– Zerlegung eines komplexen Use Cases in Teil-Use Cases. So werden die Probleme strukturierter und lassen sich besser in Teilschritten lösen.

– Überlegung, welche Art von Analyse es sein soll: Basiert diese auf bereits aggregierten Daten oder sollen Einzeldaten zur Analyse verwendet werden? Die dazugehörigen Prompts sind dann unterschiedlich, wie Teil-Use Case 1 und 2 zeigen.

– Genaue und klare Formulierung der Prompts, damit Halluzinieren und ausschweifende Formulierungen vermieden werden.

– Verwendung von KI zur Erstellung beziehungsweise Optimierung von Prompts. Hierdurch erhöht sich die Qualität der Ergebnisse noch einmal.

– Bei der Bereitstellung der Daten auf klare Formatierung und Bezeichnung achten. Umso besser kann die KI die Daten interpretieren und verarbeiten.

Nach Analyse der zehn Teil-Use Cases können die Ergebnisse noch einmal

Abbildung 8: Teil-Use Case 2 – Gegenbanken-Matrix (Migrationsströme)

Prompt an die KI – Netto-Kapitalflüsse je Wettbewerber

Da ein Kunde in verschiedenen Quartalen zu unterschiedlichen Instituten transferieren kann, müssen Aggregationen je Quartal strikt getrennt berechnet und über den Gegenbank-Namen zusammengeführt werden.

Berechnungslogik je Quartal (Q2 / Q3 / Q4)

In QX: Summe Delta QX – Filter: Art_QX == „Inflow (extern)“ AND Gegenbank_QX = jeweilige Bank

Out QX: Summe Delta QX – Filter: Art_QX == „Outflow (extern)“ (ergibt negative Werte)

Net QX: In QX + Out QX | Netto Gesamt: Net Q2 + Net Q3 + Net Q4

Ergebnistabelle (alle 6 Gegenbanken)

Gegenbank	In Q2	Out Q2	Net Q2	In Q3	Out Q3	Net Q3	In Q4	Out Q4	Net Q4	Netto Ges
Sparkasse 1	3701465	-6990432	-3288967	2380722	-5295441	-2914719	2084811	-2524291	-439480	-6643166
Sparkasse 2	2860150	-7052958	-4192808	2210491	-5037178	-2826687	1502900	-2661773	-1158873	-8178369
Genobank 1	3032999	-6344294	-3311295	2627913	-5969092	-3341179	1593404	-3061134	-1467730	-8120204
Genobank 2	3594991	-6176178	-2581186	1971170	-5326704	-3355534	1780037	-3321078	-1541041	-7477761
Direktbank 1	3399463	-9295183	-5895720	2249989	-16253139	-14003150	1808350	-24954489	-23146139	-43045009
Direktbank 2	3640319	-8639617	-4999298	2328296	-16948837	-14620541	1823037	-27699054	-25876018	-45495857
SUMME	20229387	-44498662	-24269274	13768581	-54830391	-41061810	10592539	-64221819	-53629280	-118960366

Analyseprozess: Rohdaten → Getrennte Aggregation & Merge → Netto-Matrix

ROHDATEN (AUSZUG)				AGGREGIERUNG & MERGE		NETTO-MATRIX (ERGEBNIS)				
Kontonr	Art	Δ Q2	Bank	Python → Merge	Getrennte Aggregation & Merge:		Netto- Matrix	⚠ Faktor 3,2 × Outflow Q4 vs. Q2		
500099666	Out.	-212k	Spk2		Q2: Inflow-Summe je Gegenbank			Gegenbank	Netto Ges.	Trend
500099894	Out.	-160k	Spk1		Filter: Art_Q2 == "Inflow (extern)"			Sparkasse 1	-6643166	stabil
500100001	In.	+45k	DB1		groupby(Gegenbank_Q2)			Sparkasse 2	-8178369	stabil
500099712	Int.	-8k	—		['Delta Q2'].sum()			Genobank 1	-8120204	stabil
500099578	Out.	-148k	Geno2		Q2: Outflow-Summe je Gegenbank			Genobank 2	-7477761	stabil
...		Filter: Art_Q2 == "Outflow (extern)"	Direktbank 1	-43045009	↑↑ eskaliert		
Je Quartal separat aggregieren					groupby(Gegenbank_Q2)	Direktbank 2	-45495857	↑↑ eskaliert		
					→ Merge über Banknamen	SUMME	-118960366	80 % Direktbanken		
					Net Q2 = In Q2 + Out Q2					
					Gleiche Logik für Q3 und Q4					
					⚠ Quartalsspalten strikt trennen!					
					Netto Gesamt = Net Q2 + Net Q3 + Net Q4					
					Jahressaldo je Gegenbank					

Quelle: Darstellung T.-O. Engelke, S. Reuse; auf Basis der Ergebnisse aus Google Gemini 3.1 Pro (2026)

durch einen elften Prompt analysiert werden. Dann ist der ganzheitliche Use Case vollständig und es besteht die Möglichkeit, Wechselwirkungen zu erkennen.

Die Ergebnisse der elf Prompts werden dann (noch) keine perfekten Ergebnisse sein, sehr wohl aber eine „80 bis 90-Prozent-Lösung“, die der Controller dann prüfen, veredeln und finalisieren kann. KI wird den Menschen folglich nicht ersetzen. Sie ist, wie schon viele Technologien vorher, ein Werkzeug, das dem Menschen die Arbeit erleichtert. Wich-

tig ist jedoch, dass der Mensch die finale Qualitätssicherung übernimmt. Dies bedeutet auch, dass die Verwendung von KI voraussetzt, dass die Themen vollständig vom Anwender verstanden sind und Fehler beziehungsweise Halluzinationen aufgedeckt werden können. Schlussendlich hat immer ein Mensch die Verantwortung für die Ergebnisse, nicht die KI.

Die in diesem Beitrag geäußerten Auffassungen sind die der Autoren und müssen nicht notwendigerweise mit denen des jeweiligen Arbeitgebers übereinstimmen.

Fußnoten

- 1) Die Begriffe werden im Text synonym verwendet.
- 2) Exemplarisch nach Lin, P. (2024): Amara's Law and Its Place in the Future of Tech, 06.09.2024, erhältlich auf: <https://www.computer.org/publications/tech-news/trends/amaras-law-and-tech-future>, Abfrage vom 21.02.2026.
- 3) Vgl. hierzu schon Reuse, S. / Engelke, T.-O. (2026): KI in der Gesamtbanksteuerung – Use Cases für den Risikobericht – Effizienzsteigerung durch die Nutzung Künstlicher Intelligenz zur Analyse von Risikodaten sowie der Erstellung von Kommentierungen am Beispiel Adressrisiko, in: Bank-Praktiker, 21. Jg., Ausgabe 03/2026, S. 58 – 63.
- 4) Vgl. Finanz Informatik (2024): Der S-KI Pilot: Ihr digitaler Assistent für den Sparkassen-Alltag, erhältlich auf: <https://www.f-i.de/loesungen/das-machen-wir/produkte/der-s-ki-pilot-ihr-digitaler-assistent-fuer-den-sparkassen-alltag>, Abfrage vom 21.12.2025.
- 5) Vgl. IT Finanzmagazin (2024): Atruvia Solution



Abbildung 9: Teil-Use Case 2 – Churn Scoring (Einlagen-Frühwarnsystem)

Prompt an die KI – Abwanderungs-Score auf Kundenebene

Aggregiere Kontodaten zwingend auf Kundenebene (Kunden_ID) und wende ein fünfdimensionales Regelwerk an:

1. Aggregation Konten → Kunden

Vol_Q1, Vol_Q4: Summe 30.03. / 31.12. je Kunden_ID | Giro_Vol_Q4: nur Produkt == ‚Giro‘ | Flags (0/1): Hat_Sparbrief, Hat_Anlage, Out_Q3, Out_Q4, Out_DB_Q4

2. Scoring-Regelwerk (Startwert 0,0)

Block	Regel
[A]	Geschäftlich + 1,0 1 Konto + 1,5 2 Konten + 1,0 Hat_Sparbrief – 2,0
[B]	Vol_Q4 > 500 k + 3,0 > 100 k + 2,0 > 50 k + 1,0 (höchstes zutreffendes)
[B]	Giro_Vol > 50 k UND kein Anlageprodukt → + 2,0 (Zins-Frust)
[B]	Giro_Vol < 100 → + 3,0 (Zombie-Konto)
[C]	Out_Q4 + 1,0 Trend Q3+Q4 + 2,0 Direktbank-Abfluss + 2,0
[C]	Vol_Q4 < 20 % von Vol_Q1 → + 4,0 < 50 % → + 2,0 (exklusiv)
MAX	TOTAL SCORE = 11,5 Punkte (Maximalscore)

3. Sortierung: TOTAL SCORE absteigend | Tie-Breaker: Kunden_ID aufsteigend

Analyseprozess: Kontenebene → Scoring-Logik (Kundenebene) → Top-15 Churn-Kandidaten

ROHDATEN (KONTENEbene)				SCORING-LOGIK (KUNDENEbene)		TOP-15 ERGEBNIS (CHURN-KANDIDATEN)		
Kunden_ID	Prod.	Vol Q4	Art	Score-Berechnung je Kunde:		Kunden_ID	Gruppe	SCORE
1075640	Giro	105k	Out.	A: Kundenprofil		1075640	Geschäftlich	11,5
1075640	TG	0	—	Geschäftlich → + 1,0		1075681	Geschäftlich	11,5
1075641	Giro	12k	—	Einzelkonto → + 1,5 (Hat_Sparbrief: – 2,0)		1079017	Geschäftlich	11,5
1075641	Spar	85k	—	B: Volumen & Zinsrisiko		1079247	Geschäftlich	11,5
1075642	Giro	320k	Out.	Vol_Q4 > 100k → + 2,0		1079473	Geschäftlich	11,5
1075643	Giro	8k	Intern	Giro ohne Anlage → + 2,0 (Zins-Frust)		1080316	Geschäftlich	11,5
...	C: Abflussverhalten		1080501	Geschäftlich	11,5
Konten → Kunden aggregieren				Out_Q4 → + 1,0		1081028	Geschäftlich	11,5
				Trend Q3+Q4 → + 2,0		1083430	Geschäftlich	11,5
Python → Pandas				Direktbank Q4 → + 2,0		1083807	Geschäftlich	11,5
				MAX SCORE = 11,5 Punkte		1084340	Geschäftlich	11,5
Score → Ranking				+ Geschäftlich + Einzelkonto		1085364	Geschäftlich	11,5
				+ Vol 100k–500k + kein Anlageprodukt		1086509	Geschäftlich	11,5
				+ Trend Q3+Q4 + Direktbank-Abfluss		1086556	Geschäftlich	11,5
						1087136	Geschäftlich	11,5

Quelle: Darstellung T.-O. Engelke, S. Reuse; auf Basis der Ergebnisse aus Google Gemini 3.1 Pro (2026)

Days: plainGPT und GenoGPT – so kommt die KI ins Geno-Banking, erhältlich auf: <https://www.it-finanzmagazin.de/atruvia-solution-days-plaingpt-genogpt-217743/>, Abfrage vom 21.12.2025.

6) Ausführlicher diskutiert in Reuse, S. / Engelke, T.-O. (2026), a.a.O. (Fn. 3), S. 59.

7) Vgl. Golem.de (2023): Sicherheitsbedenken: Banken verbieten Verwendung von Chat GPT, erhältlich auf: <https://www.golem.de/news/sicherheitsbedenken-banken-verbieten-verwendung-von-chat-gpt-2302-172191.html>, Abfrage vom 21.12.2025; McKinsey (2024): The State of AI in 2024: Gen AI adoption spikes and starts to generate value, erhältlich auf: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-2024>, Abfrage vom 21.12.2025. Diskutiert in Reuse, S. / Engelke, T.-O. (2026), a.a.O. (Fn. 3), S. 59.

8) Vgl. exemplarisch schon vor längerer Zeit Propach, J. / Reuse, S. (2004): Das Data Warehouse Konzept als integraler Bestandteil eines effizienten Bankcontrollings: Aufbau, Anwendungsfelder

und Informationsbedarfsanalyse, in: Controller Magazin, 29. Jg. März 2004, Ausgabe 02/2004, Offenburger und Wörthsee/München, S. 138 – 144.

9) Vgl. EU (2024): Verordnung (EU) 2024/1689 des Europäischen Parlaments und des Rates vom 13. Juni 2024 zur Festlegung harmonisierter Vorschriften für künstliche Intelligenz und zur Änderung der Verordnungen (EG) Nr. 300/2008, (EU) Nr. 167/2013, (EU) Nr. 168/2013, (EU) 2018/858, (EU) 2018/1139 und (EU) 2019/2144 sowie der Richtlinien 2014/90/EU, (EU) 2016/797 und (EU) 2020/1828 (Verordnung über künstliche Intelligenz, Amtsblatt der Europäischen Union, 12.07.2024 Reihe L, S. 1 – 144, erhältlich auf: https://eur-lex.europa.eu/legal-content/DE/TXT/PDF/?uri=OJ:L_202401689, Abfrage vom 22.02.2026.

10) Vgl. BaFin (2025): Orientierungshilfe zu IKT-Risiken beim Einsatz von KI in Finanzunternehmen, Stand 18.12.2025, erhältlich auf: https://www.bafin.de/SharedDocs/Downloads/DE/Anlage/neu/dl_Anlage_orientierungshilfe_IKT_Risiken_bei_KI.pdf?__blob=publicationFile&v=6, Abfrage vom 22.02.2026.

11) Piechatzek (2023): KI im Marketing – Warum andere plötzlich schneller sind, Präsentation am 28.08.2023, Tonspur.

12) Vgl. BaFin (2024a): Anlage 2: Mindestanforderungen an das Risikomanagement – MaRisk, Änderungen im Vergleich zur MaRisk-Fassung vom 29.06.2023, erhältlich auf: https://www.bafin.de/SharedDocs/Downloads/DE/Rundschreiben/dl_Anlage_2_2024-05-29-aenderungen_RS_06_2024_pdf_BA.pdf?__blob=publicationFile&v=3, Abfrage vom 29.05.2024, BT 3.

13) Da es sich um ein fiktives Beispiel handelt, welches die Funktionsweise verdeutlichen soll, greifen die Aspekte Datenschutz und Informationssicherheit hier nicht.

14) Vgl. Barkow Consulting (2025): Verlieren Direktbanken Marktanteile?, 16.09.2025, erhältlich auf: <https://www.barkowconsulting.com/verlieren-direktbanken-marktanteile/>, Abfrage vom 14.03.2026.

Abbildung 10: Teil-Use Case 2 – Deckungsbeitrags-Impact (Marktzinsmethode)

Prompt an die KI – Margen-Analyse (Bundesbank LSI-Stresstest-Methodik)

Berechne entgangene Deckungsbeiträge aus externen Q4-Abflüssen nach der Marktzinsmethode, angelehnt an die Bundesbank-Ausfüllhinweise zum LSI-Stresstest (2024).

Parameter (Replikationsportfolio)

Parameter	Wert	Ablauffiktion	Strukturmarge
Marktzins Kurz (2J)	2,02 %	Giro Ablauffiktion	20 % kurz / 80 % lang → Strukturmarge: 0,53 %
Marktzins Lang (10J)	2,68 %	Tagesgeld Ablauffiktion	50 % kurz / 50 % lang → Strukturmarge: 0,33 %

Filter & Formelwerk je Konto

Filter: Bewegung_Art_Q4 == „Outflow (extern)“ AND Produkt € {Giro, Tagesgeld} | Abfluss_Q4 = abs(Delta Q4)

Formel	Definition
Konditionenmarge	= Marktzins_Kurz (2,02%) – Zinssatz_Konto
Strukturmarge	= Kalk. Mischzins – Marktzins_Kurz (Fristentransformation)
Gesamtmenge	= Konditionenmarge + Strukturmarge
Verlust p.a.	= Abfluss_Q4 × Gesamtmenge

Top-10 nach DB-Verlust p.a. (Sortierung: Verlust_Gesamt_EUR absteigend)

Kunden_ID	Gruppe	Produkt	Abfluss Q4	VI. Kondition	VI. Struktur	DB-Verlust p.a.
1099546	Kommunal	TG	833 937	12 675,85	2 751,99	15 427,84
1099575	Kommunal	Giro	414 069	8 364,18	2 186,28	10 550,47
1099937	Kommunal	TG	354 817	5 393,22	1 170,90	6 564,11
1099977	Kommunal	TG	343 259	5 217,54	1 132,75	6 350,29
1099707	Kommunal	TG	308 133	4 683,62	1 016,84	5 700,46
1099939	Kommunal	TG	272 353	4 139,77	898,77	5 038,54
...
GESAMT		14 275 Konten	64 221 820	1 051 166	241 630	1 292 795

Analyseprozess: Outflow-Konten → Margen-Berechnung → DB-Verlust Ranking

ROHDATEN (OUTFLOW KONTEN)				Margen BERECHNUNG		DB-VERLUST (ERGEBNIS)					
Kunden_ID	Prod.	Vol Q4	Art	Margen → Formel	Formel-Schritte je Konto:		Verlust → Ranking	Kunden_ID	Abfluss Q4 in €	DB-Verlust p.a. in €	
500099546	0 %	– 834k	TG		Schritt 1: Konditionenmarge	= 2,02 % – Zinssatz_Konto		1099546	833 937	15 427,84	
500099575	0 %	– 414k	Giro		Giro (0,0 %): Marge = 2,02 %			1099575	414 069	10 550,47	
500099937	0 %	– 355k	TG		Schritt 2: Strukturmarge	Giro: 2,55 % – 2,02 % = 0,53 %		1099937	354 817	6 564,11	
500099977	0 %	– 343k	TG		Tagesgeld: 2,5 % – 2,02 % = 0,33 %			1099977	343 259	6 350,29	
500099707	0 %	– 308k	TG		Schritt 3: Gesamtmenge	Giro: 2,55 % Tagesgeld: 2,35 %		1099707	308 133	5 700,46	
...		Schritt 4: DB-Verlust p.a.	= Abfluss_Q4 × Gesamtmenge		1099939	272 353	5 038,54	
14 275 Outflow-Konten					833 937 € × 1,852 % = 15 428 €			1099835	262 612	4 858,32	
					Gesamt: 81 % Kondition / 19% Struktur			1099867	252 991	4 680,33	
								1099780	178 083	4 537,55	
							1099959	242 109	4 479,01		
								
							GESAMT	64 221 820	1 292 795,11		

Quelle: Darstellung T.-O. Engelke, S. Reuse; auf Basis der Ergebnisse aus Google Gemini 3.1 Pro (2026)

15) Vgl. PwC (2024): Deutsche Banken: Kompendium Marktanteile, erhältlich auf: <https://www.pwc.de/de/finanzdienstleistungen/deutsche-banken-kompendium-marktanteile.html>, Abfrage vom 14.03.2026.

16) Vgl. BaFin (2024b): Risiken aus signifikanten Zinsanstiegen, erhältlich auf: https://www.bafin.de/DE/Aufsicht/Fokusrisiken/Fokusrisiken_2024/RIF_1_Zinsanstieg/RIF_1_Zinsanstieg_node.html, Abfrage vom 14.03.2026.

17) Für die Abbildung 6 – 10 sind die Prompts verkürzt dargestellt worden, um die Lesbarkeit zu erhöhen.

18) Vgl. Deutsche Bundesbank (2024): LSI-Stresstest 2024 – Institutsübergreifendes Auskunftsersuchen, 28.03.2024, S. 10 – 13, erhältlich auf: <https://www.bundesbank.de/resource/blob/773102/5fed2fc137-78cf6dde636bbfd9c8195/472B63F073F071307366337C94F8C870/Isi-st2024-ausfuellhinweise-data.pdf>, Abfrage vom 14.03.2026.