

Whitepaper

Causal Guardrail Reasoning

Produktionstaugliche KI-Systeme durch die Verknüpfung
von LLMs und kausaler Logik

© Deepsearch GmbH

Mai 2026

Inhaltsverzeichnis

Einleitung.....	3
Unterscheidung zwischen probabilistischen LLMs und deterministischen KI-Systemen.....	4
Korrelation versus Kausalität.....	4
Mathematische Grundlagen der Probabilistik in LLMs.....	5
Wissensgraphen als deterministische Weltmodelle.....	5
Vergleichende Systemarchitektur.....	6
Schwachstellen von probabilistischen LLMs.....	7
Das Problem der Faktentreue und Halluzinationen.....	7
Black-Box-Natur und mangelnde Erklärbarkeit.....	7
Model Drift.....	7
"Lost in the Middle"-Effekt.....	8
Herausforderungen im praktischen Einsatz vom LLMs.....	8
Verstehen ist die Grundlage jeglichen sinnvollen Handelns.....	9
Welche Vorteile ergeben sich aus der Kombination dieser beiden Technologien?.....	10
Drastische Reduktion von Halluzinationen und Steigerung der Vertrauenswürdigkeit.....	10
Erfüllung regulatorischer Compliance und Auditierbarkeit.....	10
Dynamisches Wissensmanagement und Skalierbarkeit.....	10
Die Lösung: deepassist.....	11
deepassist für Causal Guardrail Reasoning (CGR) - mehr als Retrieval Augmented Generation (RAG).....	12
Quellenverzeichnis.....	14
Abbildungsverzeichnis.....	14
Tabellenverzeichnis.....	14



Dieses Whitepaper zeigt, wie ein hybrider KI-Ansatz aus probabilistischen Large Language Models und deterministischer neurosymbolischer KI den Weg zu produktionstauglichen, zuverlässigen und transparenten KI-Systemen ebnet.

Einleitung

Mit dem Launch von ChatGPT Ende 2022 begann der beispiellose Siegeszug Transformer-basierter KI-Systeme, der die technologische Landschaft nachhaltig verändert hat. Die beeindruckende Fähigkeit dieser Modelle, menschliche Sprache zu verstehen und zu generieren, hat weltweit hohe Erwartungen in die Leistungsfähigkeit künstlicher Intelligenz geweckt. In der Folge haben Unternehmen branchenübergreifend ambitionierte KI-Projekte initiiert, um das enorme Potenzial von Generative AI (GenAI) für ihre Geschäftsmodelle zu erschließen und Innovationsvorsprünge zu sichern.

Doch mit der fortschreitenden praktischen Beschäftigung erwächst in vielen Entwicklungsabteilungen eine ernüchternde Erkenntnis: **GenAI ist kein universeller Generalschlüssel für jede komplexe Aufgabenstellung**. Bei der Umsetzung realer Projekte treten Herausforderungen zutage, die weit über die reine Textgenerierung hinausgehen. Die größte Hürde besteht oft darin, **die Systeme deterministisch zu steuern** – sie also verlässlich dazu zu bringen, genau das zu tun, was sie sollen, und dabei strikte Business-Logiken einzuhalten.

Dieses Whitepaper zeigt einen Weg auf, wie die Implementierung und insbesondere die Bereitstellung von produktionstauglichen Large Language Models (LLMs) gelingt. Im Fokus steht dabei ein hybrider KI-Ansatz, der die kreative Flexibilität von LLMs mit der Präzision und Verlässlichkeit deterministischer Systeme verbindet, um insbesondere im anspruchsvollen Bereich des Kundenservice sichere und optimale Ergebnisse zu erzielen.



Unterscheidung zwischen probabilistischen LLMs und deterministischen KI-Systemen

Die wissenschaftliche Differenzierung zwischen probabilistischen und deterministischen Systemen bildet das Fundament für das Verständnis moderner KI-Architekturen. Ein deterministisches System ist dadurch definiert, dass es bei identischen Eingangsbedingungen zwingend und **ausnahmslos dasselbe Ergebnis liefert**. Die internen Zustandsübergänge folgen festen Regeln, die keine Zufallselemente zulassen. Im Gegensatz dazu operieren probabilistische Systeme auf der Basis von Wahrscheinlichkeitsverteilungen. Ihre Ausgaben sind das Resultat statistischer Schätzungen über die Plausibilität einer Antwort in einem gegebenen Kontext, wobei identische Eingaben aufgrund von Parametern wie der Temperatur-Einstellung oder der inhärenten Stochastik des Sampling-Prozesses zu variierenden Ergebnissen führen können.

Korrelation versus Kausalität

Ein zentrales Missverständnis beim Einsatz von Large Language Models (LLMs) rührt von der Verwechslung zwischen statistischer Korrelation und logischer Kausalität her. Da Transformer-Modelle auf der Berechnung von Auftrittswahrscheinlichkeiten basieren, identifizieren sie hochkomplexe Muster und Beziehungen zwischen Token innerhalb riesiger Datenmengen. Diese Korrelationen erlauben es dem Modell, semantisch plausible Antworten zu generieren, die oberflächlich wie logische Schlussfolgerungen wirken. Doch das Modell „berechnet“ lediglich die Nähe von Begriffen zueinander; **es versteht nicht die zugrunde liegenden Ursache-Wirkungs-Prinzipien**.




Abbildung 1: Der Unterschied zwischen Korrelation und Kausalität

Die Kausalität hingegen erfordert ein deterministisches Modell der Welt, in dem A zwingend zu B führt, weil eine physikalische oder logische Regel existiert. Während ein LLM aufgrund einer Korrelation im Trainingsset vielleicht „weiß“, dass auf die Frage nach einem Rabatt oft ein Prozentsatz folgt, fehlt ihm das kausale Verständnis der betriebswirtschaftlichen Bedingungen, unter denen dieser Rabatt gewährt werden darf. Ohne diese Verankerung in der Kausalität **bleibt das neuronale Netz anfällig für Halluzinationen** – es verknüpft Begriffe, die statistisch



korrelieren, aber in der spezifischen Business-Logik keinen kausalen Zusammenhang besitzen.

Mathematische Grundlagen der Probabilistik in LLMs

Moderne Sprachmodelle wie GPT-5 oder Gemini basieren auf der Transformer-Architektur, die Sprache als eine Sequenz von Token modelliert. Der Kernprozess ist die Vorhersage der Wahrscheinlichkeit des nächsten Tokens $P(x_t | x_{[1]}, \dots, x_{[t-1]})$. Diese Wahrscheinlichkeit wird durch eine Softmax-Funktion berechnet, die die Logits¹ des Modells in eine Verteilung transformiert, die sich zu eins aufsummiert. Ein LLM **"verstehet" keine Fakten im ontologischen Sinne**; es erkennt vielmehr hochkomplexe statistische Muster in den Trainingsdaten, um eine Fortsetzung zu generieren, die den gelernten Verteilungen am besten entspricht. Diese probabilistische Natur erlaubt es den Modellen, mit unstrukturierten Daten umzugehen, Nuancen in der menschlichen Sprache zu erfassen und kreativ auf ambivalente Anfragen zu reagieren, führt jedoch auch zu einer mangelnden Reproduzierbarkeit und Vorhersagbarkeit.

Wissensgraphen als deterministische Weltmodelle

Deterministische KI-Systeme, insbesondere solche, die Wissensgraphen (Knowledge Graphs, KGs) nutzen, verfolgen einen symbolischen Ansatz. Ein Wissensgraph repräsentiert Informationen als ein Netzwerk aus Entitäten (Knoten) und deren Beziehungen (Kanten), häufig formalisiert in RDF-Tripeln (Subjekt-Prädikat-Objekt). Diese Struktur fungiert als ein explizites Weltmodell, in dem Fakten nicht implizit in Gewichten versteckt, sondern explizit kodiert sind. Die Abfrage eines solchen Graphen erfolgt über formale Sprachen, die mathematisch exakte und logisch herleitbare Antworten liefern. Ein solches System ist inhärent transparent: **Jede Antwort kann bis zu ihrem Ursprung im Graphen zurückverfolgt werden**, was eine vollständige Auditierbarkeit ermöglicht.

¹ Ein Logit ist in der Statistik und beim maschinellen Lernen der natürliche Logarithmus der Chance, dass ein bestimmtes Ereignis eintritt.



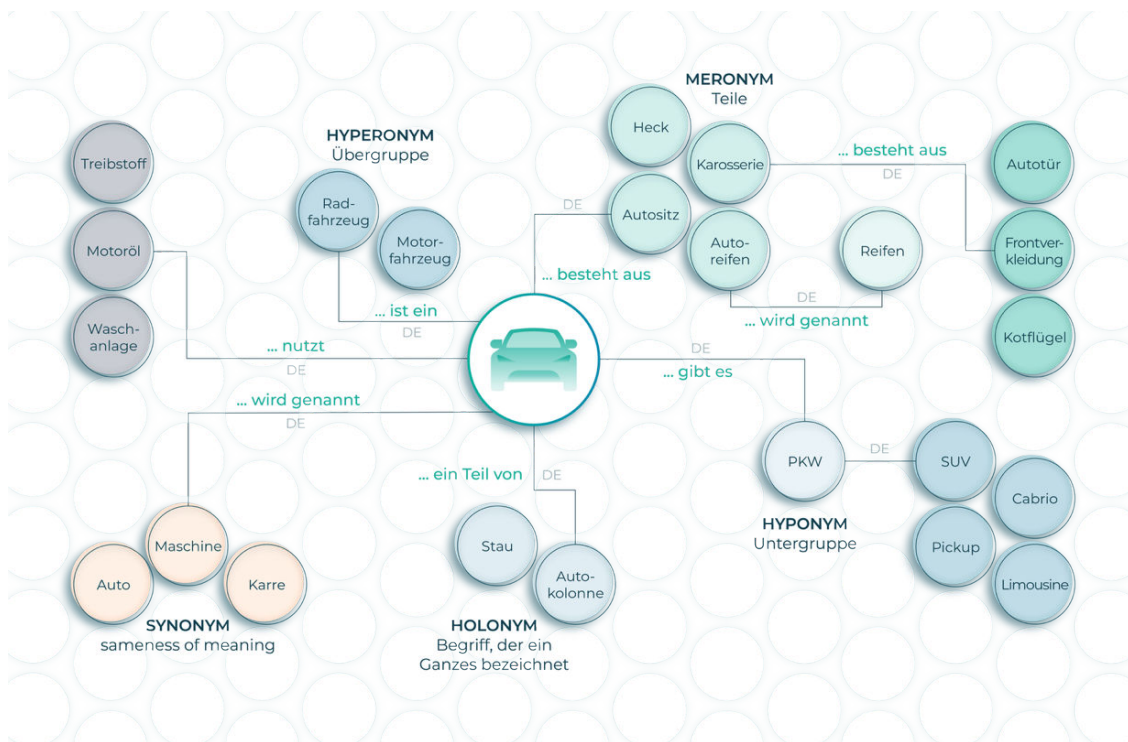


Abbildung 2: Ein Wissensgraph besteht aus Knoten und verbindenden Kanten

Vergleichende Systemarchitektur

Die folgende Tabelle illustriert die komplementären Eigenschaften beider Ansätze, die die Grundlage für die spätere Diskussion der Hybridisierung bilden:

Merkmal	Probabilistische LLMs	Deterministische Wissensgraphen
Wissensrepräsentation	Implizit (neuronalen Gewichte)	Explizit (Knoten und Kanten)
Logik	Statistische Korrelation	Symbolische Deduktion
Output-Charakter	Variabel und generativ	Konsistent und extraktiv
Transparenz	Black-Box-Modell	Glass-Box-Modell (auditierbar)
Datenstruktur	Unstrukturiert (Textkorpora)	Strukturiert (Ontologien)
Fehlverhalten	Halluzinationen möglich	Logische Lücken, aber keine Erfindungen
Domänenanpassung	Fine-Tuning (teuer)	Graph-Updates (kosteneffizient)

Tabelle 1: Vergleich der Systemarchitekturen

In der Praxis des Kundenservice bedeutet dies, dass ein LLM zwar hervorragend darin ist, eine freundliche, kontextbezogene und ansprechende Antwort zu formulieren, aber unzuverlässig bei der Formulierung von inhaltlich korrekten Aussagen. Ein Weltmodell (Wissensgraph) hingegen kennt die Zusammenhänge der Welt exakt, kann diese aber ohne Hilfe nicht in einen flüssigen Kundendialog einbetten.



Schwachstellen von probabilistischen LLMs

Die beeindruckenden Fähigkeiten von LLMs bei der Sprachgenerierung dürfen nicht über ihre fundamentalen Schwächen hinwegtäuschen, die insbesondere im professionellen Dialogmanagement erhebliche Risiken bergen.

Das Problem der Faktentreue und Halluzinationen

Die gravierendste Schwäche probabilistischer Modelle ist das Auftreten von Halluzinationen. Da das Modell lediglich Token-Wahrscheinlichkeiten berechnet, kann es Antworten generieren, die oberflächlich betrachtet hochgradig plausibel erscheinen, aber keine Entsprechung in der Realität haben. In der Forschung wird hierbei zwischen "Faithfulness" (Übereinstimmung mit der Quelle) und "Factualness" (Übereinstimmung mit Weltwissen) unterschieden. Halluzinationen entstehen oft durch lückenhafte Trainingsdaten, veraltete Informationen oder die Tendenz des Modells, Mustern den Vorzug vor Fakten zu geben. Studien beziffern die **Halluzinationsrate bei Standard-LLMs auf 15 bis 20 Prozent**, was für geschäftskritische Anwendungen inakzeptabel ist.

Black-Box-Natur und mangelnde Erklärbarkeit

LLMs sind aufgrund ihrer Architektur mit Milliarden von Parametern für den Menschen undurchsichtig. Es ist de facto unmöglich nachzuvollziehen, warum ein Modell eine bestimmte Entscheidung getroffen hat. Diese fehlende Interpretierbarkeit ist in regulierten Industrien problematisch. Die **Datenschutz-Grundverordnung (DSGVO) fordert in Artikel 22** bei automatisierten Einzelentscheidungen, dass betroffene Personen **das Recht haben, eine Erläuterung der involvierten Logik zu erhalten**. Ein rein probabilistisches System kann diese Forderung nicht zuverlässig erfüllen, da es keinen expliziten Argumentationspfad gibt, der auf logischen Regeln basiert.

Model Drift

Unter Model Drift versteht man das Phänomen, dass die **Leistungsfähigkeit** oder das Antwortverhalten **eines KI-Modells über die Zeit nachlässt** oder sich unvorhersehbar verändert, obwohl das Modell selbst nicht neu trainiert wurde. Bei LLMs tritt dies häufig auf, wenn sich die zugrunde liegende Datenverteilung der realen Welt ändert (Data Drift) oder wenn die Entwickler das Modell im Hintergrund durch Updates (z. B. Reinforcement Learning from Human Input-Anpassungen zur Sicherheit oder Effizienz) modifizieren. Ein bekanntes Beispiel ist die Beobachtung, dass Modelle bei komplexen Aufgaben wie dem Lösen von Mathematikaufgaben oder dem Schreiben von Code plötzlich "schlechter" oder "fauler" werden, weil eine Optimierung in einem Bereich (z. B. Sicherheit) unbeabsichtigte Nebenwirkungen auf andere Fähigkeiten hat.



“Lost in the Middle“-Effekt

Der Lost-in-the-Middle-Effekt beschreibt eine U-förmige Leistungskurve bei der Verarbeitung langer Kontexte: Large Language Models (LLMs) rufen Informationen am Anfang (Primacy) und am Ende (Recency) eines Prompts sehr präzise ab, **verlieren aber in der Mitte massiv an Genauigkeit**. Selbst Modelle mit theoretisch riesigen Kontextfenstern von Hunderttausenden Token neigen dazu, Details zu "übersehen", wenn diese tief im "Bauch" eines Dokuments vergraben sind. Das liegt primär an der Funktionsweise der Aufmerksamkeitsmechanismen (Attention), die dazu neigen, den Fokus auf den einleitenden Kontext und die unmittelbar vor der Antwort stehenden Instruktionen zu legen.

Herausforderungen im praktischen Einsatz vom LLMs

Ein fundamentales Merkmal Transformer-basierter KI-Systeme ist das Fehlen eines intrinsischen Konzepts von „Wahrheit“ oder logischer Korrektheit. Da diese Modelle **ohne eine explizite Ground-Truth** operieren, basiert ihre Arbeitsweise rein auf der statistischen Vorhersage des jeweils nächsten Tokens. Der Prozess der Interpretation, Problemlösung und Antwortgenerierung verschmilzt dabei zu einem einzigen Vorgang. Anstatt einer deduktiven Logik zu folgen, „hangelt“ sich das Modell auf Basis von Wahrscheinlichkeiten von Token zu Token.

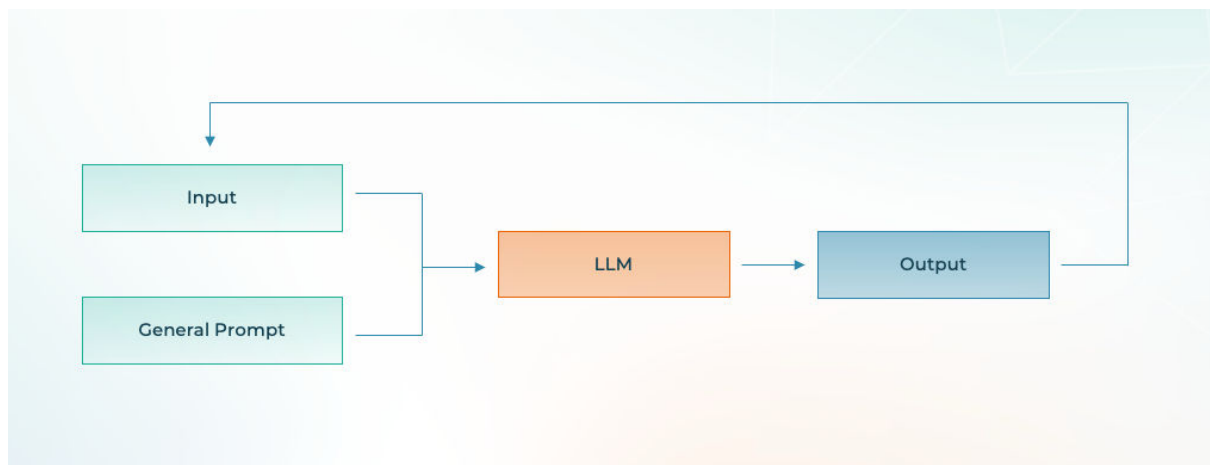


Abbildung 3: Datenfluss ohne CGR



In der operativen Praxis führt diese Architektur zu signifikanten Hürden: Die generierten Antworten auf Kundenanfragen divergieren häufig von den definierten Kommunikationsrichtlinien oder fachlichen Vorgaben des Unternehmens. Aufgrund der probabilistischen Natur von LLMs bleibt der Entstehungsprozess einer Antwort zudem **weitestgehend intransparent**; er lässt sich weder kausal nachvollziehen noch im klassischen Sinne debuggen. Für Entwickler endet die Optimierung daher oft in einem ineffizienten Trial-and-Error-Verfahren beim Prompt Engineering.

Verschärft wird diese Instabilität durch externe Faktoren wie Model Drift oder iterative Updates der Modellversionen durch die GenAI-Provider. Solche Modifikationen können dazu führen, dass **ein System, das gestern noch valide Ergebnisse lieferte, plötzlich ein völlig verändertes Antwortverhalten zeigt**. Für Unternehmen entsteht dadurch ein unkalkulierbares Risiko bei der Bereitstellung konsistenter Kundenerlebnisse.

Verstehen ist die Grundlage jeglichen sinnvollen Handelns

三思而後行

„Ein Mann soll dreimal nachdenken, bevor er handelt.“ (Konfuzius)

Um die inhärenten Schwächen rein probabilistischer Modelle zu überwinden, setzt die nächste Generation von Enterprise-Lösungen auf hybride Architekturen, auch **Composite AI** genannt. In diesen Frameworks fungieren deterministische KI-Systeme, die auf strukturierten Wissensgraphen basieren, als stabilisierende Weltmodelle für die Sprachmodelle. Während das LLM die linguistische Schnittstelle bildet, **liefert der Wissensgraph das faktische Rückgrat**. Informationen werden nicht mehr allein aus den statistischen Gewichten des neuronalen Netzes generiert, sondern gegen eine explizit definierte Wissensbasis geprüft und durch diese gesteuert.

Das strategische Ziel dieser Integration ist es, die kreative und linguistische Flexibilität neuronaler Netze mit der unbestechlichen Präzision und logischen Strenge symbolischer KI zu vereinen. In einer solchen Konfiguration dient das LLM als hochgradig adaptives Dialog-Interface, während das deterministische System die Einhaltung von Geschäftsregeln, Faktenkonsistenz und Prozesslogiken garantiert. Nur durch diese Synergie lassen sich moderne, dialogorientierte Anwendungen realisieren, die den hohen Anforderungen an Sicherheit und Vorhersehbarkeit im professionellen Kundenservice gerecht werden.



Welche Vorteile ergeben sich aus der Kombination dieser beiden Technologien?

Die Synergie von probabilistischen und deterministischen Ansätzen transformiert die KI von einem faszinierenden Prototyp zu einem **verlässlichen Werkzeug für den Unternehmenseinsatz**. Im Bereich des Kundenservice lassen sich diese Vorteile in konkrete Leistungsmetriken übersetzen.

Drastische Reduktion von Halluzinationen und Steigerung der Vertrauenswürdigkeit

Durch die Erdung des LLMs in einem verifizierten Wissensgraphen wird das Risiko von Falschaussagen auf ein Minimum reduziert. In Bereichen, wo Präzision unumgänglich ist, ermöglicht **erst dieser hybride Ansatz den produktiven Einsatz der KI**.

Erfüllung regulatorischer Compliance und Auditierbarkeit

Die Integration symbolischer Logik **löst das "Black-Box-Problem"**. Jede Antwort eines hybriden Systems kann mit einer Quellenangabe belegt werden. Dies ist die Voraussetzung für die Einhaltung der DSGVO und des kommenden EU AI Acts, da es eine **"erklärbare KI" (XAI)** schafft. Unternehmen können so gegenüber Regulierungsbehörden und Kunden nachweisen, auf welcher Datenbasis und nach welchen Regeln eine Auskunft oder Entscheidung zustande kam. Durch die Nutzung von **Knowledge Guardrails** wird zudem sichergestellt, dass regulatorische Schwellenwerte exakt eingehalten und nicht durch "kreative" LLM-Interpretationen verwässert werden.

Dynamisches Wissensmanagement und Skalierbarkeit

Ein hybrides System ist wesentlich einfacher zu warten. Während das Fine-Tuning eines LLMs Tausende von GPU-Stunden kosten kann, ist **das Update eines Wissensgraphen eine Standard-Datenbankoperation**. Dies erlaubt es Unternehmen, auf Marktveränderungen oder neue Produktveröffentlichungen in Echtzeit zu reagieren. Zudem ermöglicht der Einsatz von **Small Language Models (SLMs)** in Verbindung mit Wissensgraphen den Betrieb leistungsstarker KI-Lösungen auf lokaler Hardware, was Datenschutzbedenken adressiert, und Cloud-Kosten minimiert. Zusammenfassend lässt sich festhalten, dass die Unterstützung probabilistischer Systeme durch deterministische Weltmodelle den entscheidenden Schritt von der explorativen zur angewandten KI markiert. Die technologische Symbiose ermöglicht Systeme, die nicht nur die Sprache der Menschen sprechen, sondern auch die Regeln und Fakten der Geschäftswelt unfehlbar beherrschen. Für den Kundenservice der Zukunft bedeutet dies eine Abkehr von starren Chatbots hin zu intelligenten Agenten, die sowohl empathisch als auch absolut präzise agieren können.



Die Lösung: deepassist

deepassist ist eine **hochspezialisierte NLU-Engine** (Natural Language Understanding), die auf den Prinzipien einer neurosymbolischen KI basiert. Im Gegensatz zu rein statistischen Modellen ist das System in der Lage, umgangssprachliche Texte nicht nur hinsichtlich ihrer Semantik (Bedeutung), sondern auch in ihrem pragmatischen Kontext (Handlungsabsicht) tiefgreifend zu verstehen. Durch die Integration **branchenspezifischer Weltmodelle** generiert deepassist ein **kausales Sprachmodell**, das einen Paradigmenwechsel zu herkömmlichen Architekturen darstellt.

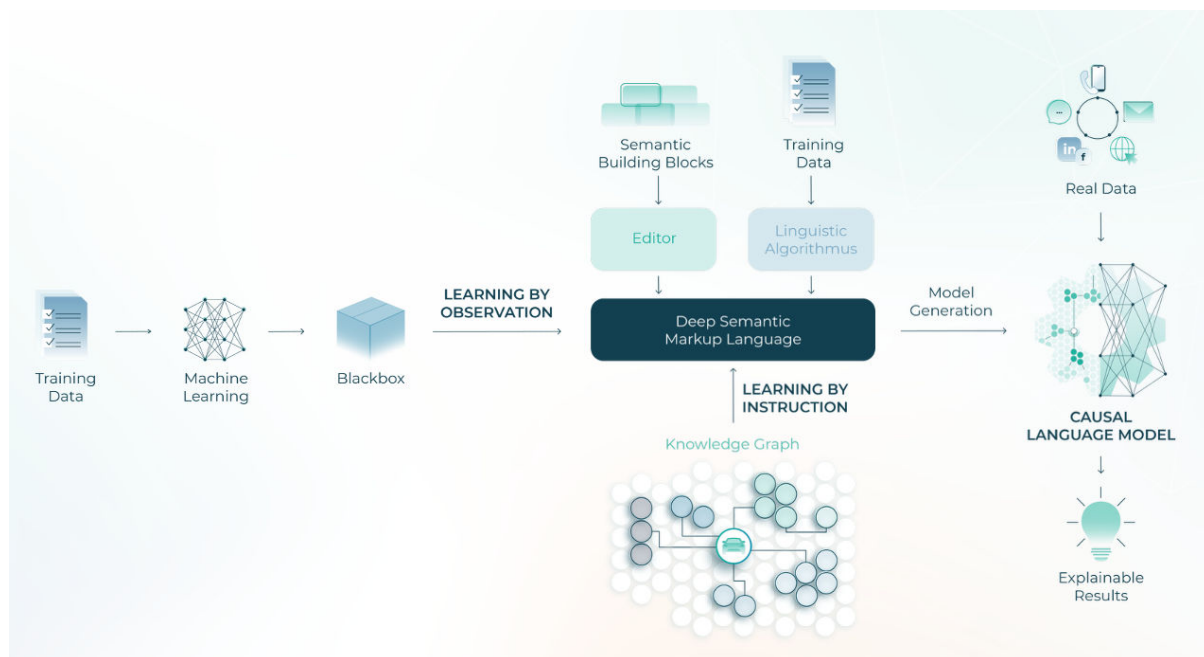


Abbildung 4: Grundprinzip von deepassist

Statt auf einem neuronalen Netz mit Milliarden von probabilistisch gewichteten Parametern zu fußen, basiert die Entscheidungslogik von deepassist auf einem komplexen Gefüge aus Billionen von expliziten Regeln. Dieser Aufbau transformiert die Sprachverarbeitung von einer statistischen „Blackbox“ in ein transparentes, logisches System. Das Ergebnis ist ein **vollumfänglich interpretierbares Modell**, dessen Entscheidungsprozesse bei der Textanalyse Schritt für Schritt auditiert und nachvollzogen werden können – eine unverzichtbare Voraussetzung für die Compliance und Qualitätssicherung im professionellen Kundenservice.



deepassist für Causal Guardrail Reasoning (CGR) - mehr als Retrieval Augmented Generation (RAG)

Mit deepassist CGR verschmelzen probabilistische und deterministische KI-Technologien zu einer wegweisenden Architektur, bei der deepassist das "Verstehen" übernimmt und auf dieser Basis eine sehr **feingranulare Steuerung** des LLM ermöglicht.

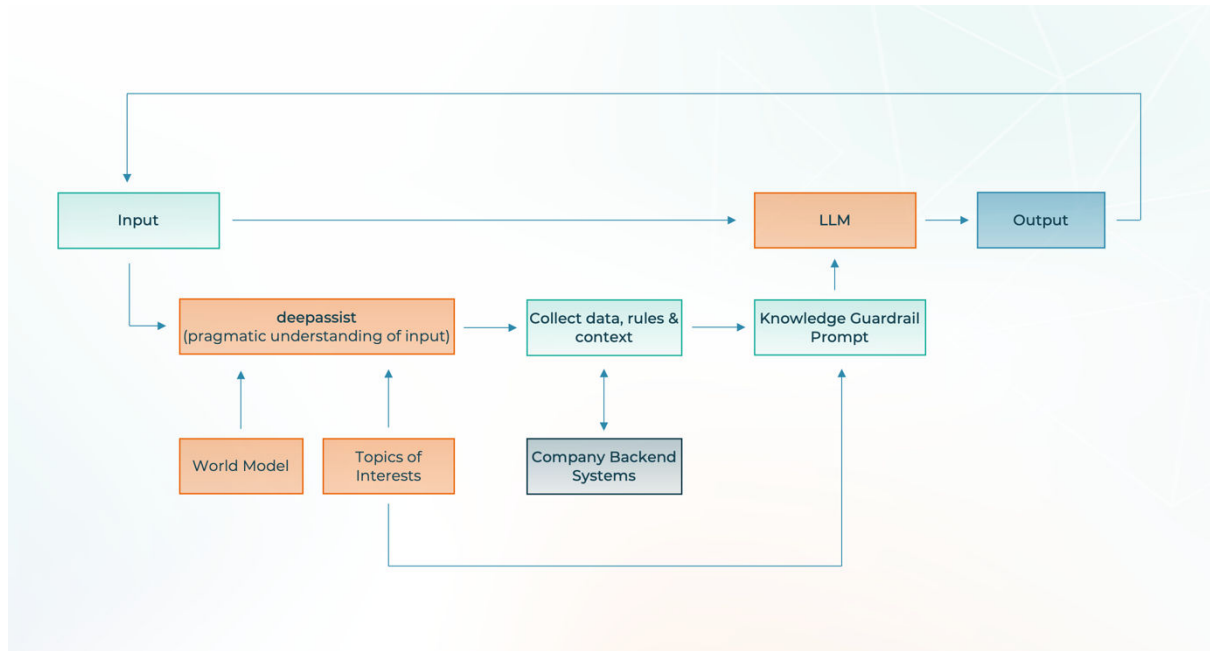


Abbildung 5: Datenfluss mit CGR

Bei CGR wird in einem ersten Schritt die Eingabe des Users mit Hilfe eines Weltmodells auf seinen pragmatischen Inhalt hin analysiert. **deepassist versteht die Eingabe und versteht den Kontext.** Daraufhin ist es in der Lage einen maßgeschneiderten Prompt zu generieren, der nicht nur spezifische, auf den Input bezogene Anweisungen für das LLM enthält, sondern auch notwendige Zusatzinformationen, die einen zielgerichteten und fachlich korrekten Output des LLM gewährleistet.

Gartner

„Focusing exclusively on GenAI is a guarantee to fail. AI leaders struggle to understand when and when not to apply generative AI (GenAI) for their use cases. The hype surrounding GenAI can lead them to apply it where it is not a good fit, increasing the risk of higher complexity and failure in their AI projects.“ (Gartner, ID G00838885, Juli 2025)



Dass dieser neue technologische Ansatz **tatsächlich wegweisend** ist, belegt auch der aktuelle AI Hype Cycle des weltweit führenden IT-Analysten Gartner.




Abbildung 6: Gartner AI Hype Cycle, 2026

deepassist CGR zeigt, dass leistungsfähige, sichere und zugleich transparent auditierbare KI-Systeme nicht auf intransparente Black-Box-Modelle angewiesen sind. Durch die Kombination aus probabilistischer Sprachverarbeitung und deterministischer neurosymbolischer Logik entsteht eine technische Grundlage, die Unternehmen **echte Kontrolle, Nachvollziehbarkeit und Stabilität bietet** – selbst in hochregulierten Umgebungen. Besonders bedeutsam ist dabei, dass deepassist CGR als vollständig **europäische Technologie** entwickelt wird und damit einen entscheidenden Beitrag zur digitalen Souveränität leistet. In einer Zeit, in der kritische KI-Infrastrukturen häufig von außereuropäischen Akteuren dominiert werden, setzt deepassist CGR ein klares Zeichen: **Zukunftsweisende KI kann innovativ, vertrauenswürdig und zugleich unabhängig sein.**

Dieses Whitepaper unterstreicht damit nicht nur die technische Relevanz des hybriden Ansatzes, sondern auch seine strategische Bedeutung für eine selbstbestimmte europäische KI-Landschaft.



Quellenverzeichnis

- Auer, Sören (Februar 2026). Knowledge Graphs as Grounded World Models for Neuro-Symbolic Artificial Intelligence.
- Fleischhacker, Roland (März 2026). Lecture: Beyond Correlation: Causal AI Decisions Based on World Models. Österreichische Akademie der Wissenschaften.
- Fleischhacker, Roland (April 2026). Vorlesung: Generative AI. Universität für Weiterbildung Krems.
- Fraunhofer IESE. Halluzinationen von generativer KI und großen Sprachmodellen (LLMs).
- Gartner (Juni 2025). Hype Cycle for Artificial Intelligence, 2025.
- Gartner (Juli 2025). When Not to Use Generative AI.
- Liu, Nelson F., Lin, Kevin, Hewitt, John, Paranjape, Ashwin, Bevilacqua, Michele, Petroni, Fabio & Liang, Percy (2024). Lost in the Middle: How Language Models Use Long Contexts.
- Moses, Todd (Oktober 2023). Beyond Curve Fitting: My Journey to Causal AI.
- Studyflix.de. Korrelation vs. Kausalität: Die Unterschiede. <https://studyflix.de>
- Wei, Jerry, Huang, Jie, Yang, Chengrun, Tran, Dustin, Song, Xinying, Lu, Yifeng, Hu, Nathan, Peng, Daiyi, Du, Cosmo, Liu, Ruibo & Le, Quoc V. (2024). Long-form factuality in large language models.
- Zia, Tehseen (April 2026). Warum Large Language Models die Mitte vergessen: Aufdeckung von KI's verborgener Blindheit.

Abbildungsverzeichnis

Abbildung 1: Der Unterschied zwischen Korrelation und Kausalität	4
Abbildung 2: Ein Wissensgraph besteht aus Knoten und verbindenden Kanten	6
Abbildung 3: Datenfluss ohne CGR	8
Abbildung 4: Grundprinzip von deepassist.....	11
Abbildung 5: Datenfluss mit CGR	12
Abbildung 6: Gartner AI Hype Cycle, 2026	13

Tabellenverzeichnis

Tabelle 1: Vergleich der Systemarchitekturen	6
--	---

