WHITE PAPER

Large Human Network Models (LHNM)

The Human Intelligence Bridge. Eine neue Modellklasse zwischen künstlicher Intelligenz und menschlichem Netzwerk

Ein Thesenpapier über die Verbindung von Expertenwissen, Beziehungsnetz und großen Sprachmodellen

David A. Pieper
Investor · Unternehmer · Family Office

Erste Auflage · November 2026
© 2026 David A. Pieper. Alle Rechte vorbehalten. Dieses White Paper ist keine Anlageberatung.

Inhalt

Abstract
1 · Die Frage, die man nicht googeln kann
2 · Drei Quellen, drei Modellklassen
3 · Definition und Abgrenzung
4 · Die Daten
5 · Aufbau
6 · Wie Experten ihr Large Human Network Model aufbauen
7 · Betrieb
8 · Übertragbarkeit
9 · Wirkung
10 · Gegenthese
11 · Grenzen und testbare Hypothesen
Annex

Abstract

Große Sprachmodelle beantworten Fragen, deren Antwort in Texten steht. Ein erheblicher Teil der wirtschaftlich entscheidenden Fragen hat aber keine Antwort in Texten. Sie liegt bei Menschen: in dem, was sie können, besitzen, wollen und entscheiden, und in dem, was ein erfahrener Experte über sie weiß, ohne es je aufgeschrieben zu haben. Dieses White Paper beschreibt eine Modellklasse, die auf dieses Wissen zugeschnitten ist. Ein Large Human Network Model (LHNM) verbindet drei Dinge, die bisher getrennt existieren: das nicht veröffentlichte Fach-, Zugangs- und Verhaltenswissen eines Experten, eines Teams oder eines Hauses, einer Koryphäe ihres Gebiets, das über Jahrzehnte gewachsene Beziehungsnetz dieser Personen und die Schlussfolgerungsfähigkeit der besten großen Sprachmodelle. Das Ergebnis ist kein Sprachmodell und soll auch keines ersetzen. Es ist eine Schicht darüber, die aus einer anderen Quelle lernt als jedes Sprachmodell: nicht aus dem, was die Menschheit geschrieben hat, sondern aus dem, was eine Person oder ein Team über ihre Welt weiß und wen sie darin erreichen kann. Das Paper definiert die Klasse, grenzt sie von Vertical AI, interner Unternehmens-KI, Relationship-Intelligence-Software, Expertennetzwerken, Expertenklonen und KI-Vermittlungsdiensten ab, beschreibt Datenbasis, Architektur, Aufbau und Betrieb eines Modells, das aus einem laufenden Fall aus der Welt der Family Offices entstanden ist und dort weiterentwickelt wird, und zeigt, warum das Muster auf jede Domäne übertragbar ist, in der entscheidendes Wissen bei wenigen Menschen liegt. Was hier beschrieben wird, war bis vor wenigen Jahren nicht zu bauen: das Wissen und das Beziehungsnetz eines Menschen oder eines Hauses an einem Ort, verknüpft, abrufbar und lernfähig. Ein solches Modell lässt sich in zwei Richtungen bauen: nach außen, als Zugang zu Wissen und Menschen, der sich mit Dritten monetarisieren lässt, und nach innen, als Gedächtnis einer Expertengruppe, einer Familie oder eines Unternehmens, das sonst mit seinen Trägern verloren geht. Die Gegenthese wird am Ende mit ihren Facetten untersucht; das Paper schließt mit testbaren Hypothesen. Nach Kenntnis des Autors ist es die erste Beschreibung dieser Modellklasse unter diesem Namen.

1 · Die Frage, die man nicht googeln kann

Wer heute ein großes Sprachmodell, Google oder Perplexity fragt, wie man zum Beispiel eine große Wohnanlage mit 300 Einheiten bewertet, bekommt eine brauchbare Antwort. Wer fragt, wie man sie verwertet, bekommt keine brauchbare Antwort: welche drei Familien in den USA, in Deutschland oder in Japan genau diese beispielhafte Anlage, in dieser Lage, in dieser Qualität, zu diesem Preis, in den nächsten sechs Wochen kaufen würden, warum, und über wen man sie ansprechen muss. Es geht um ein Produkt ohne aktuelles, liquides, transparent abrufbares Preisschild, das keinen täglichen Kurs hat wie eine Aktie und das nur wenige, teils nicht einmal bekannte Personen kaufen können. Dasselbe gilt für eine Beteiligung an einem Unternehmen, einen Anteil an einem Wagniskapitalfonds, ein Kunstwerk, eine Automobilsammlung und vieles mehr. Die Antwort, die man bekommt, ist dabei selten einfach leer. Sie wirkt auf den ersten Blick oft gut, ist in Teilen halbgar, in Teilen falsch und weist nicht selten in die falsche Richtung; und sie hängt davon ab, welches Modell man benutzt und wie geübt man es befragt. Nicht, weil das Modell zu klein wäre, sondern weil die Antwort in keinem eintrainierten Text steht, den ein Modell je gelesen hat. Sie steht in den Köpfen weniger Menschen: eines inneren Kreises aus Experten, die diese Käufer und Investoren, zum Beispiel Family Offices, seit zwanzig Jahren kennen, und einiger Firmen, die mit ihnen arbeiten, wobei es auch dort wieder einzelne Personen mit besonderem Zugang sind, etwa der Makler, der seit Jahren für

die Familie tätig ist, der Wirtschaftsprüfer oder der Anwalt. Nichts von dem, was diese Menschen wissen, ist online auffindbar.

Das Muster wiederholt sich in jeder Branche, in der Entscheidungen von wenigen getroffen werden. Welcher Regisseur arbeitet erneut mit welchem Produzenten, obwohl der letzte Film gescheitert ist? Welcher Veranstalter bucht einen unbekannten Künstler auf Zuruf welcher Person? Welche Bank finanziert ein Familienunternehmen gegen Covenants statt gegen Eigenkapital, und wer dort entscheidet das? Welcher Zulieferer der Verteidigungsindustrie liefert tatsächlich, wenn es darauf ankommt? Das sind keine Wissenslücken, die das nächste, größere Modell schließt. Es sind Fragen nach Menschen, nach ihren Fähigkeiten, ihrem Kapital und ihren Entscheidungen. Die Antwort liegt im Zugang zu ihnen und im Wissen über sie. Jeder Hochvermögende kann bei einer Großbank anrufen. Wer dort aber die Beleihung von Vermögen betreut, etwa einen Lombardkredit mit Auslandsbezug, ob das Haus so etwas überhaupt macht und mit wem man darüber sprechen muss, das ist die wertvolle Information, und sie steht nirgends.

Man kann sich das Wissen der Welt als Eisberg vorstellen (Abb. 1). Über der Wasserlinie liegt alles, was geschrieben, veröffentlicht, gescannt und in Modelle trainiert wurde. Darunter liegt, was Praktiker wissen und nie aufgeschrieben haben: wer verlässlich ist, wer zahlt, wer Zusagen hält, warum ein Family Office in Bieterverfahren nie mitgeht, welcher Chirurg bei welcher Komplikation ruhig bleibt, welcher Minister welchem Botschafter vertraut. Michael Polanyi hat dafür 1966 den Satz geprägt, dass wir mehr wissen, als wir sagen können.[1] Kein Sprachmodell enthält diesen Teil des Eisbergs, gleichgültig, wie viele Milliarden in das nächste Training fließen. Er wurde nie geschrieben, und er wird es auch nicht, weil sein Wert gerade darin liegt, dass er nicht geschrieben wurde. Es ist eine ganze Welt aus Zugangswissen, Kontext und Beziehungsgeschichte, die außerhalb jedes Trainingskorpus liegt. Wenn man so will: die rote Pille aus dem Film „Matrix“.

Die These dieses Papers lautet, dass sich dieser Teil des Eisbergs erschließen lässt, aber nicht durch mehr Training auf mehr Text, sondern durch eine andere Art von Modell, das aus einer anderen Quelle lernt. Peter Thiel hat den Unterschied zwischen dem Besseren und dem Neuen als Unterschied zwischen 1 zu n und 0 zu 1 beschrieben:[2] 1 zu n heißt, etwas Vorhandenes zu verbessern oder zu vervielfachen; 0 zu 1 heißt, etwas zu schaffen, das es vorher nicht gab. Ein größeres Sprachmodell ist 1 zu n. Ein Modell, das aus Menschen lernt statt aus Texten, beginnt bei null.

Ein Wort dazu, warum dieses Paper jetzt geschrieben wird und nicht vor zehn Jahren. Wer lange mit solchen Netzen arbeitet, hat versucht, sie festzuhalten: in Datenbanken, in Kundensystemen, mit eigenen Entwicklern, teuer und immer nur in Teilen, weil die Verbindungen zwischen den Einträgen im Kopf bleiben mussten. Eine Datenbank weiß, dass zwei Namen existieren. Sie weiß nicht, dass der eine dem anderen seit zwölf Jahren einen Gefallen schuldet. Seit Sprachmodelle lesen, verknüpfen und Schlüsse ziehen können, lässt sich dieses Wissen zum ersten Mal an einer Stelle zusammenführen, mit allen Verbindungen, und es lernt dabei laufend weiter. Diejenigen, die davon am meisten hätten, wissen noch nicht, dass oder wie es funktioniert.



Abb. 1: Der Eisberg des Wissens. Über der Wasserlinie, was geschrieben wurde und in Sprachmodelle trainiert ist; darunter, was nie geschrieben wurde. Eigene Darstellung. © 2026 David A. Pieper.

2 · Drei Quellen, drei Modellklassen

Die großen Modellklassen der Gegenwart lassen sich danach ordnen, woraus sie lernen. Diese Achse ist für das Verständnis wichtiger als die Frage, wie ein Modell gebaut ist, denn sie bestimmt, welche Fragen es beantworten kann (Abb. 2).

Large Language Models lernen aus Text, und aus Gesprochenem, das transkribiert wurde und damit wieder Text ist. Die Transformer-Architektur[3] und die Skalierung auf Hunderte Milliarden Parameter[4] haben Modelle hervorgebracht, die aus dem, was die Menschheit geschrieben hat, erstaunlich viel von dem rekonstruieren, was sie weiß. Ihre Grenze ist die Grenze des Geschriebenen.

World Models lernen aus der physischen Welt. Der Begriff geht auf David Ha und Jürgen Schmidhuber zurück, die 2018 generative Modelle einer Umgebung beschrieben, in der ein Agent handelt.[5] Yann LeCun hat ihn 2022 zum Kern einer Architektur autonomer Maschinen gemacht.[6] Seit 2025 sind World Models Industrie: NVIDIA stellte mit Cosmos eine Plattform für „Physical AI“ vor,[7] und World Labs, das von Fei-Fei Li mitgegründete Unternehmen, soll nach einer im September 2026 angekündigten Vereinbarung für rund 8,2 Milliarden US-Dollar in Aktien von AMD übernommen werden.[8] World Models lernen, wie sich Dinge im Raum verhalten, damit Roboter und Fahrzeuge darin handeln können. Ihre Grenze ist die Grenze des Messbaren. Wie früh das alles noch ist, zeigt der Stand: 2025 wurden weltweit rund 13.000 humanoide Roboter ausgeliefert,[9] und die Brücke in die physische Welt wird im Wesentlichen von Menschen gebaut. Tesla bezahlt seit 2024 Beschäftigte dafür, in Motion-Capture-Anzügen und mit VR-Brillen Bewegungen vorzuführen, die der Roboter nachahmen soll;[10] Datenfirmen lassen Tausende Menschen in mehr als fünfzig Ländern Alltagshandgriffe für Roboter filmen;[11] Google DeepMind hat 2023 mit 33 Laboren Demonstrationsdaten von 22 Robotertypen zusammengelegt.[12] Kritiker wie der Robotiker Rodney Brooks, Mitgründer von iRobot, halten den ersten profitablen Einsatz humanoider Roboter für mehr als zehn Jahre entfernt.[13]

Large Human Network Models lernen aus Menschen. Sie lernen, wer was weiß, kann, besitzt, will und entscheidet, mit wem er es seit wann tut und wie man ihn erreicht. Ihre Quelle ist nicht die Menschheit, sondern eine Person, ein Team oder ein Haus mit Jahrzehnten an Zugang zu einer Welt, die sich nicht aufschreiben lässt. Ihre Grenze ist die Grenze dieses Zugangs.

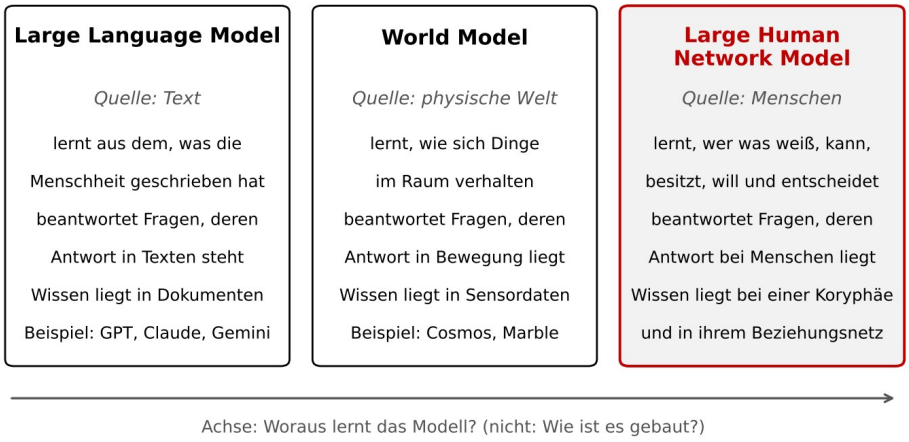

Quelle: eigene Darstellung. © 2026 David A. Pieper

Abb. 2: Drei Modellklassen, geordnet nach ihrer Lernquelle. Eigene Darstellung. © 2026 David A. Pieper.

Zwei weitere Entwicklungen gehören nicht in diese Reihe, obwohl sie oft daneben genannt werden. Die erste sind Agenten: Sprachmodelle, die handeln, Werkzeuge bedienen und Aufgaben über Stunden allein erledigen. OpenAI hat im September 2026 mit „Dots“ dauerhaft laufende Agenten vorgestellt,[14] Meta hat seinem Assistenten mit Muse Spark 1.1 im Juli 2026 Agentenfunktionen gegeben.[15] Agenten werden Arbeitsplätze übernehmen und Branchen verändern. Sie ändern aber im Kern nichts daran, woraus das Modell lernt. Ein Agent kann Register abfragen, Mails schreiben und Termine vereinbaren. Er kann keinen Vertrauten anrufen, keinen Aktenschrank öffnen, keine Datenbank lesen, zu der ihm niemand Zugang gibt, und er kann nicht zu Mittag essen und dabei Vertrauliches besprechen. Die zweite Entwicklung ist die sich selbst verbessernde KI, in der Forschung als recursive self-improvement bezeichnet. Googles AlphaEvolve hat 2025 Rechenkerne beschleunigt, die das Training seiner eigenen Grundlage verkürzen,[16] und Dario Amodei, Mitgründer von Anthropic, schrieb im September 2026, dieser Prozess beginne bereits in der gesamten Branche.[17] Beides beschreibt, wie Modelle handeln und wie sie besser werden, nicht, woraus sie lernen. Dasselbe gilt für Quantenrechner und die Software, die auf ihnen laufen wird. Es sind andere Achsen, die jede der drei Klassen beschleunigen können, auch die hier beschriebene.

Zwei Gräben

Die Lage lässt sich als Landschaft zeichnen (Abb. 3). In der Mitte liegt, was KI heute erreicht: alles, was je geschrieben wurde, zunehmend auch das Handeln in Software. Links davon liegt die physische Welt, getrennt durch einen Graben, den World Models und Physical AI gerade überbrücken wollen, gebaut unter anderem aus Vorführungen, Simulation und Sensorik. Rechts liegt die menschliche Welt: Vertraute, frühere Kunden, Aktenschränke, geschlossene Systeme, Erfahrungswissen, das Wissen

darüber, wer was weiß, kann, will und entscheidet. Über diesen zweiten Graben führt bisher keine Brücke, und Agenten reichen bis an seinen Rand und nicht weiter.

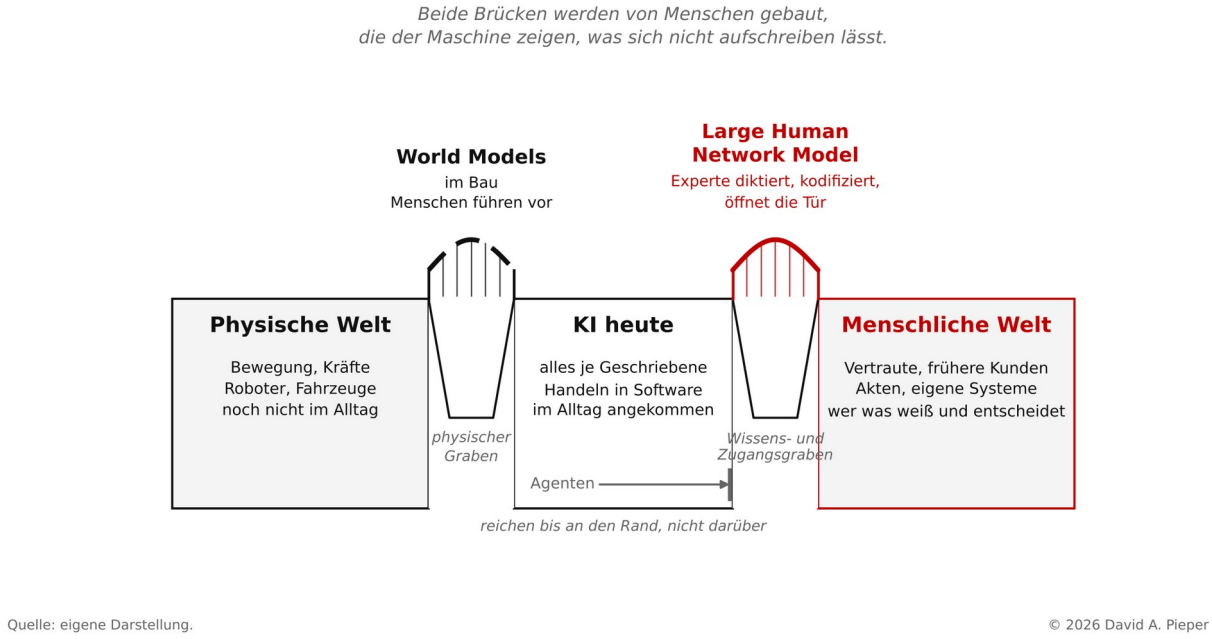

Abb. 3: Zwei Gräben. Was KI heute erreicht, was sie nicht erreicht, und welche Brücke wohin führt. Eigene Darstellung. © 2026 David A. Pieper.

Ein Large Human Network Model ist die Brücke über den zweiten Graben, und sie wird nach demselben Prinzip gebaut wie die erste: Ein Mensch zeigt der Maschine, was sich nicht aufschreiben lässt. Beim Roboter führt er die Bewegung vor. Beim LHNM diktiert und beschreibt der Experte sein Urteil, „trainiert“ es im übertragenen Sinn, und öffnet die Tür. Diese Parallele ist mehr als ein Bild. Sie ist auch die Antwort auf die Frage, warum ein LHNM ein Modell ist, auf die der nächste Abschnitt zurückkommt.

3 · Definition und Abgrenzung

Definition

Ein Large Human Network Model ist ein KI-System mit fünf Eigenschaften. Erstens ist es auf dem nicht veröffentlichten Fach-, Zugangs- und Verhaltenswissen eines ausgewiesenen Experten, eines Teams oder eines Hauses aufgebaut. Zweitens enthält es dessen reales Beziehungsnetz als strukturierte Datenbasis, in der jeder Eintrag mit Herkunft, Zeit und Kontext versehen ist. Drittens nutzt es ein großes Sprachmodell als austauschbare Schlussfolgerungsmaschine. Viertens beantwortet es Fragen, deren Antwort bei Menschen liegt. Fünftens öffnet es den Weg zu diesen Menschen tatsächlich, durch den Experten, das Team oder das Haus selbst oder durch Personen, die sie dazu autorisiert haben. Nach außen gibt es nicht das Netz heraus, sondern Antworten und geöffnete Türen. Die Rohdaten verlassen den Tresor nie.

Der Kernsatz lautet: **Large Language Models beantworten Fragen, deren Antwort in Texten steht. Ein Large Human Network Model beantwortet Fragen, deren Antwort bei Menschen liegt: in ihren Fähigkeiten, ihrem Kapital, ihren Entscheidungen.** Es ist die Brücke zwischen künstlicher und menschlicher Intelligenz, und zwar in beide Richtungen: Die Maschine erschließt das Wissen des Menschen, und der Mensch gibt der Maschine Zugang zu einer Welt, die

sie allein nie erreicht. Abb. 4 zeigt dieses Bild als Hängebrücke: Zwei Pylone tragen: der Experte mit seinem Urteil und seinen gesetzten Gewichten und das Netz mit seinen Beziehungen über Jahrzehnte. Das gemietete Sprachmodell ist das Tragkabel, das die Last verteilt und austauschbar bleibt. Konnektoren, Skills, Gedächtnis und Regelwerke sind die Hänger. Über die Fahrbahn gehen in die eine Richtung Anliegen, in die andere Antworten und geöffnete Türen, nie Rohdaten. Die Rohdaten liegen in den Fundamenten unter Wasser, im eigenen Tresor.

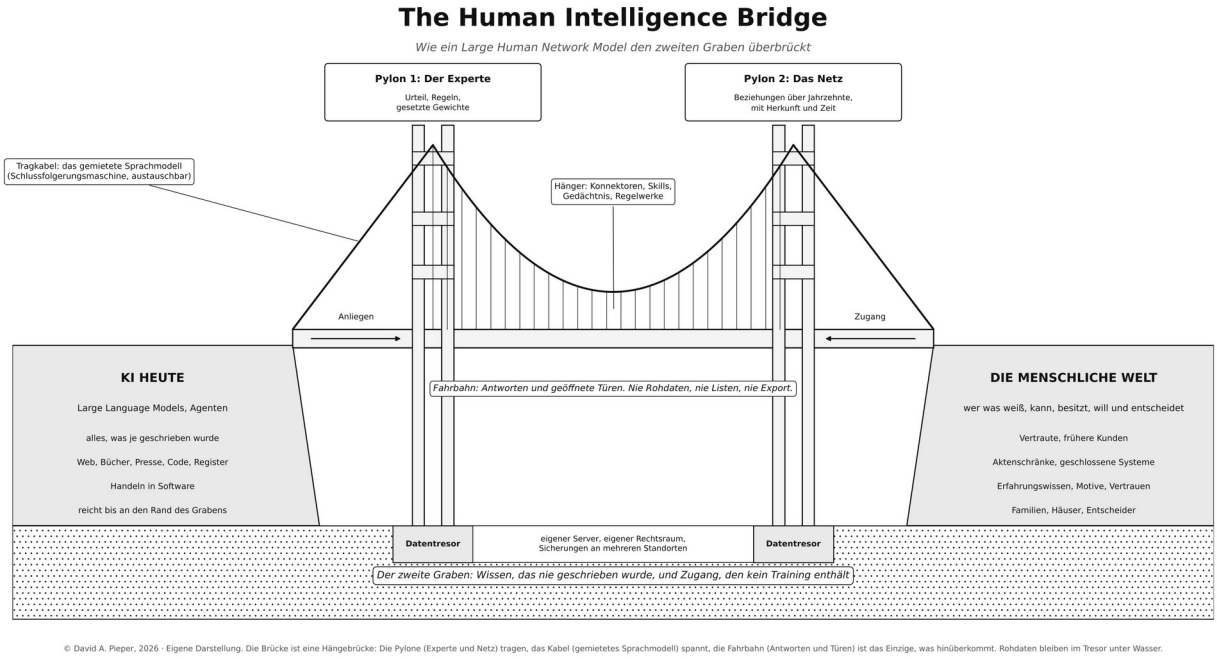

Abb. 4: The Human Intelligence Bridge. Ein Large Human Network Model als Hängebrücke über den zweiten Graben. Eigene Darstellung. © 2026 David A. Pieper.

Gesetzte Gewichte, lebende Parameter

Die naheliegende Frage an diese Definition lautet, was an einem solchen System mathematisch ein Modell ist, wenn es keine eigenen Gewichte trainiert. Die genaue Antwort ist: Es trainiert keine gelernten Gewichte, aber es hat gesetzte. Formal ist ein LHNM ein gewichteter, gerichteter Graph mit einer Bewertungsfunktion darüber.[18] Die Knoten sind Menschen und Häuser mit Eigenschaften: Stufe des Zugangs (im beschriebenen Fall drei Stufen), Rolle, Entscheidungsmacht, Kapital, Motivlage. Die Kanten sind Beziehungen mit Stärke, Richtung, Vertrauen, Gegenseitigkeit und Datum des letzten Kontakts. Darüber liegt eine Funktion, die für ein konkretes Anliegen den besten Pfad durch dieses Netz bestimmt, ähnlich wie PageRank die Bedeutung einer Seite aus der Struktur der Verweise ableitet,[19] nur dass die Gewichte hier nicht aus einer Struktur errechnet, sondern vom Experten gesetzt werden: Der Kontakt zu einem Eigentümer wiegt mehr als der zu einem Vermittler, ein Vermittler wird nur über den Eigentümer angesprochen, unter drei Treffern wird nichts angezeigt. Was im beschriebenen Fall heute als Regelwerk in Textform vorliegt, ist diese Funktion, nur noch nicht als Formel geschrieben.

Drei Dinge folgen daraus. Erstens sind es wenige Parameter, alle lesbar, alle prüfbar, alle von einer Person, einem Team oder einem Haus verantwortet. Das ist der Gegensatz zu den Milliarden Gewichten eines Sprachmodells, von denen keines für sich etwas bedeutet und deren Zusammenspiel selbst die eigenen Entwickler und Forscher nicht im Einzelnen nachvollziehen können. Im LHNM entscheidet ein

einzelner Parameter darüber, ob eine Familie mit einem Milliardenvermögen zu einem Anliegen überhaupt angesprochen wird und über wen. Nicht die Zahl der Parameter macht das Modell, sondern was ein einzelner Parameter bewegt, und dahinter steht eine Datenbasis, die es sonst nirgends gibt: Text aus dem Internet ist im Überfluss vorhanden, einige zehntausend geprüfte Hochvermögende mit Beziehungsgeschichte, wie im beschriebenen Fall, sind es nicht. Zweitens ist das Schema allgemein und sind die Werte individuell. Zugangsstufen, Wertklassen, Beziehungsstärke, Vertrauen gelten für jeden Experten in jeder Domäne; wer bei ihm auf der ersten Stufe steht und was bei ihm als wertvoll zählt, bestimmt er allein. Das Schema ist damit das Übertragbare, die Werte sind das Betriebsgeheimnis. Drittens sind die Gewichte gesetzt, aber nicht statisch. Sie ändern sich auf drei Wegen, und darin unterscheidet sich das System von einem Sprachmodell, dessen Gewichte sich nur durch ein neues Training mit neuen Daten ändern und die danach niemand lesen kann: Der Experte setzt sie und ändert sie, wenn sich sein Urteil ändert; die Arbeit schreibt sie fort, weil jede Anfrage, jede Vorstellung und jede Reaktion Beziehungsstärke und Vertrauen verschiebt; und die Maschine schlägt Änderungen vor, wenn sie in neuen Daten sieht, dass ein Kontakt die Rolle gewechselt, ein Haus verkauft oder ein Vermittler nicht geliefert hat, und der Experte bestätigt. Das ist Lernen ohne Backpropagation, eher ein Vertrauenswert, der sich fortschreibt. Ein LHNM ist in diesem Sinn ein lebendes Parametersystem. Zugleich wächst es mit jedem Fortschritt der Sprachmodelle mit, weil es deren gesamtes Welt- und Kontextwissen jederzeit hinzuziehen kann.

Dazu kommt eine zweite Ebene, die erst ab einer bestimmten Datenmenge sichtbar wird: Muster. Bei dreißig Kontakten gibt es keine Muster, nur Einzelfälle. Bei dreißigtausend tauchen Regelmäßigkeiten auf, die kein Experte vollständig im Kopf hat: welches Family Office in welcher Phase verkauft, welche Vermittler tatsächlich liefern, welcher Zugangsweg bei welchem Typ von Gegenüber funktioniert, welche Anfragen scheitern und woran. Das ist Statistik über den Korpus, nicht Gedächtnis, und das Sprachmodell erkennt sie über die Masse, während der Experte sie sofort prüfen kann, weil er die Fälle kennt. Der Chirurg, der tausend Prominente operiert hat, ist handwerklich nicht zwingend besser als der, der einen operiert hat. Er kennt die Verteilung: was dieser Typ Patient erwartet, zahlt, verschweigt, wo er abspringt. Dieses Wissen liegt nicht in einem Kontakt, sondern zwischen den Kontakten, und es ist ein weiterer Grund, warum „Large“ im Namen steht. Unterhalb einer Schwelle ist ein solches System ein Adressbuch mit Notizen. Oberhalb ist es ein Modell.

Ein Kritiker wird einwenden, das sei ein Bewertungssystem, kein Modell. Die Statistik sieht das anders: Ein Modell ist eine parametrisierte Funktion über Daten, und ob die Parameter geschätzt oder gesetzt werden, ändert daran nichts.[20] Das Paper bleibt deshalb bei dem Wort, sagt aber genau, was gemeint ist: ein kleines, lesbares, von einem Menschen verantwortetes Parametersystem über einer knappen Datenbasis, verbunden mit einem großen, gemieteten Sprachmodell, das die Muster darin findet.

Warum „Model“ und warum „Large“

Der zweite Einwand liegt auf der Hand: Die großen Gewichte, die das Sprachmodell ausmachen, trainiert ein LHNM nicht. Es mietet sie. Ist es dann überhaupt ein Modell oder nur eine Anwendung? Die Antwort liegt in dem, was das System repräsentiert. Ein World Model heißt so, weil es eine gelernte, laufend aktualisierte Darstellung einer Welt enthält, nicht, weil es auf einem bestimmten Chip läuft. Ein LHNM enthält eine gelernte, laufend aktualisierte Darstellung eines menschlichen Netzes: wer, was, mit wem, seit wann, aus welchem Motiv, mit welchem Ergebnis. Diese Darstellung ist das Modell. Das Sprachmodell ist die Maschine, die es liest, befragt und mit dem

Wissen der Welt verbindet. Beides zusammen bildet ein System, das mit jeder Anfrage, jedem Urteil und jedem Ergebnis dazulernt, also genau das tut, was man von einem Modell erwartet. Und es entsteht auf dieselbe Weise wie ein World Model: Ein Mensch zeigt der Maschine, was in keinem Text steht, dort durch Vorführen, hier zum Beispiel durch Diktieren und Entscheiden. Offen gesagt: Die Gewichte gehören dem Anbieter. Das Modell des Netzes und das darin kodierte Urteil gehören dem Experten. **Jeder kann die beste KI mieten. Niemand kann zwanzig Jahre Beziehungen mieten.** Auf der physischen Seite des Grabens ist diese Arbeitsteilung bereits eine eigene Kategorie mit eigenem Kapitalmarkt. Das Münchner Unternehmen microagi, 2025 gegründet, baut nach eigener Darstellung weder Roboter noch Grundmodelle, sondern eine hardware- und modellagnostische Schicht, die vorhandene Modelle mit den Betriebsdaten des Kunden und einem eigenen Datenkorpus auf die Fabrik des Kunden anpasst, ohne Bindung an einen Anbieter;[21] im Juli 2026 erhielt es dafür 55 Millionen US-Dollar, die größte Seed-Finanzierung, die es in Deutschland bisher gab, angeführt von Hummingbird Ventures mit Northzone, LocalGlobe, Village Global und redalpine.[22] Dort heißt das Post-Training, und microagi gilt als Forschungslabor. Ein LHNM ist dasselbe Prinzip auf der menschlichen Seite: nicht das Grundmodell, sondern die Schicht, die es mit dem verbindet, was nur der Eigentümer hat.

„Large“ bezeichnet hier nicht die Zahl der Parameter, sondern den Umfang des Korpus und die Reichweite des Netzes: Korrespondenz über Jahrzehnte in der Größenordnung mehrerer hunderttausend Nachrichten und Anhänge, strukturierte Bestände in der Größenordnung von tausend Tabellen und hunderttausend Datensätzen, Tausende persönlich bekannter Entscheider. Das ist für ein Sprachmodell klein und für ein menschliches Netz außergewöhnlich groß.

Was ein LHNM nicht ist

Die Bausteine eines LHNM existieren einzeln. Das Paper beansprucht nicht, sie erfunden zu haben. Es legt dar, dass ihre Verbindung eine eigene Klasse bildet. Deshalb werden im Folgenden die verwandten Spielarten, Modelle und Ausprägungen aufgeführt und es wird offengelegt, wo nach Einschätzung des Autors die Unterschiede liegen (Tabelle 1).

Vertical AI heißt in der Sprache der Wagniskapitalgeber die Anwendung großer Modelle auf eine Branche mit deren eigenen Daten und Abläufen.[23] Harvey für Kanzleien wurde im September 2026 mit 15,5 Milliarden US-Dollar bewertet,[24] Abridge für Arztgespräche 2025 mit 5,3 Milliarden.[25] Die abwertende Bezeichnung „Wrapper“ hat sich mit diesen Bewertungen erledigt.[26] Die Investorenlogik dahinter ist bemerkenswert und stützt dieses Paper: Modelle werden austauschbar, wahrscheinlich zur Handelsware (Commodity); der Burggraben sind Daten, die niemand sonst hat.[27, 28] Ein LHNM ist in diesem Sinn eine Vertical AI. Der Unterschied liegt in dem, was kodiert wird. Vertical AI kodiert die Dokumente und Prozesse einer Branche. Ein LHNM kodiert die Menschen und Beziehungen eines Experten, Teams oder Hauses und öffnet die Tür zu ihnen.

Interne Wissens-KI in Kanzleien, Banken und Konzernen antwortet aus dem eigenen Dokumentenbestand und sagt, wer im Haus sich mit einer Frage auskennt. Die Antwort ist ein Dokument oder ein Kollege, das System dient den eigenen Leuten, und normalerweise verkauft kein Haus Zugang zu seinem Beziehungsgraphen, weil die Beziehungen das Geschäft selbst sind. Eine Bank weiß intern, wer wen kennt, und macht daraus normalerweise kein Produkt für Dritte.

Relationship-Intelligence-Software wie Affinity oder Louisa AI kartiert aus Beziehungsdaten, bei Louisa ausdrücklich aus Mails und Kalendern, wer im eigenen Haus den wärmsten Draht zu einem Ziel hat, und schlägt den Weg vor.[29, 30] Das ist technisch der nächste Verwandte der Datenschicht eines LHNM. Es fehlen das Urteil eines Experten, der Zugang von außen und die Tür.

Expertennetzwerke wie GLG, AlphaSights oder Third Bridge verkaufen Gespräche mit fremden Fachleuten auf Stundenbasis. Sie haben keine Beziehungsdaten, kein Modell und keinen Experten, der für die Verbindung mit seinem Namen einsteht. Dienste wie Pearl schalten einer solchen Vermittlung inzwischen eine KI vor.[31]

Expertenklone wie Delphi, das 2025 eine Finanzierung unter Führung von Sequoia erhielt, trainieren ein Abbild einer Person auf deren Texten, Podcasts und Beiträgen und verkaufen Gespräche damit.[32] Das ist die nächste Verwandtschaft auf der Wissensseite. Es fehlen das Netz, das nie veröffentlichte Wissen und die Tür. Ein Klon kann sagen, was ein Experte gesagt hat. Er kann niemanden anrufen und sich mit niemandem treffen.

KI-Vermittlungsdienste wie Boardy[33] oder die 2026 gestartete, von der KI „Cupid“ gestützte Kapitalvermittlung AYU Capital der Family-Office-Community AYU[34, 35] stellen Verbindungen zwischen ihren eigenen Nutzern her. Das Netz entsteht aus selbst beschriebenen Profilen und Mandaten, nicht aus Jahrzehnten gemeinsamer Geschäfte; das Urteil liegt bei einem Team oder bei der Maschine, nicht bei einer Person, deren Name auf der Gegenseite etwas bedeutet. Marktplätze wie PartnerHQ gehen einen Schritt weiter und lassen Netzwerkinhaber warme Vorstellungen gegen ein Entgelt verkaufen,[36] ohne Modell und ohne Wissen. Das ist der nächste Vorläufer für die Monetarisierung eines eigenen Netzes nach außen, und zugleich das Gegenteil eines LHNM: Es verkauft die Verbindung und hat kein Urteil.

Tabelle 1: Nachbarn eines Large Human Network Models im Vergleich. Eigene Einordnung auf Basis öffentlicher Produktbeschreibungen, Stand Oktober 2026.

	Proprietäre Beziehungsdaten	Expertenwissen, nie veröffentlicht	KI-Urteil	Persönlich geöffnete Tür	Von außen zugänglich
Interne Wissens-KI (Harvey u. a.)	teils	nein	ja	nein	nein
Relationship Intelligence (Affinity, Louisa)	ja, intern	nein	teils	nein	nein
Expertennetzwerk (GLG, AlphaSights)	nein	nein	nein	nein	ja
Expertenklon (Delphi, Viven)	nein	nein, nur Veröffentlichtes	ja	nein	ja
KI-Vermittlungsdienst (Boardy, AYU)	nein, Nutzerprofile	nein	teils	nein	ja
Intro-Marktplatz (PartnerHQ)	ja, viele Einzelne	nein	nein	ja, gegen Entgelt	ja
Large Human Network Model	ja	ja	ja	ja	ja

Der zweite Anlauf

Die Frage, ob man das Wissen eines Experten, Teams oder Hauses in eine Maschine bekommt, ist nicht neu. Die künstliche Intelligenz hat es schon einmal versucht. Edward Feigenbaum, Stanford, beschrieb 1977 in seinem Grundsatztext zur

Wissensingenieurkunst die Beschaffung des Expertenwissens als das Flaschenhalsproblem beim Bau intelligenter Systeme und schrieb über den Experten: Ein großer Teil dieses Wissens sei privat, und er wisse mehr, als ihm bewusst sei.[37] Die Expertensysteme jener Zeit, MYCIN für die Medizin, DENDRAL für die Chemie, XCON für die Konfiguration von Rechnern bei Digital Equipment, stießen an genau dieser Stelle an ihre Grenze: Wissensingenieure mussten das Wissen von Hand in Regeln übersetzen, die Experten konnten nicht sagen, was sie wussten, und die Regelbasen verfielen. Bei XCON wuchs der Bestand auf 6.200 Regeln, von denen sich jedes Jahr rund die Hälfte änderte.[38] Die Betriebswirtschaft hat das Problem später unter dem Namen Externalisierung beschrieben, die Umwandlung stillschweigenden in ausdrückliches Wissen, ohne eine Maschine zu haben, die sie leisten könnte.[39]

Heute wird Expertenwissen in drei Formen geerntet, und keine davon ist ein LHNM. Die erste ist die Ernte für alle: Eine eigene Industrie bezahlt Fachleute dafür, ihr Wissen in Trainingsdaten für die großen Modelle zu verwandeln. Mercor erreichte im Juni 2026 eine Umsatzrate von über zwei Milliarden US-Dollar mit mehr als 30.000 wöchentlich aktiven Experten,[40] OpenAI ließ Berichten zufolge mehr als hundert frühere Investmentbanker Finanzmodelle bauen, an denen seine Modelle lernen.[41] Das ist das genaue Gegenstück zu einem LHNM: Das Wissen wird generisch, fließt in ein Modell, das jeder mieten kann, und nichts davon bleibt beim Experten, am wenigsten sein Netz. Die zweite Form sind Werkzeuge nach innen: Kanzleien verwandeln mit Harvey ihr Hauswissen in wiederverwendbare Abläufe,[42] Konzerne lassen Systeme wie Glean ihre Dokumente erschließen und Beschäftigte finden, die sich auskennen. Das bleibt im Haus und kodiert Prozesse, nicht das Urteil einer Person. Die dritte Form sind Klone und Türöffner, getrennt voneinander: Delphi und MasterClass verkaufen Gespräche mit dem KI-Abbild eines Experten, trainiert auf dem, was er veröffentlicht oder ihnen überlassen hat;[32, 43] Boardy und Affinity vermitteln Vorstellungen ohne Urteil. Niemand verbindet beides.

Dass der zweite Anlauf anders ausgehen kann als der erste, zeigt die Forschung der letzten zwei Jahre. Ein KI-Agent, der in einer Simulation Mitarbeiter einer Organisation befragte, rekonstruierte undokumentiertes Wissen in rund 95 Prozent der Läufe vollständig,[44] und eine Studie aus dem Jahr 2026 fand, dass Sprachmodelle stillschweigendes Wissen aus dem Verhalten von Experten besser herausholen als die Experten selbst.[45] Feigenbaums Flaschenhals öffnet sich, weil die Maschine den Experten versteht, statt auf seine Regeln zu warten. Das ist der technische Grund, warum ein LHNM heute gebaut werden kann und 1985 nicht. Der zweite Grund ist, dass niemand damals das Netz mitgedacht hat: Ein Expertensystem sollte wissen, was der Experte weiß. Ein LHNM weiß außerdem, wen er kennt.

Zum Begriff

Der Name „Large Human Network Model“ ist bewusst in die Reihe von Large Language Model und World Model gestellt. Das Wort „Human“ beschreibt die Funktion. Ohne dieses Wort heißt „Network“ in der Technikwelt zuerst Kommunikationsnetz oder neuronales Netz: Eine japanische Forschergruppe hat „Large Network Model“ 2025 für ein Sprachmodell verwendet, das Kommunikationsnetze simuliert,[46] und die Kurzform LNM wird für „Large Numerical Models“[47] und für Refik Anadols „Large Nature Model“[48] gebraucht. Das Netz, um das es hier geht, besteht aus Menschen, und der Name hebt das hervor. Der nächste Namensverwandte ist ein Essay von 2025, der unter „Large Relationship Models“ die Vision eines Plattformmodells entwirft, das aus den aggregierten Beziehungsdaten vieler Nutzer lernen soll, welche Verbindungen Wert schaffen.[49] Der Unterschied ist

grundsätzlich: Dort lernt ein Modell aus dem Verhalten vieler, hier aus dem Wissen und dem Netz einer Person, eines Teams oder eines Hauses. Dort gibt es kein Expertenwissen, keinen Türöffner und keine Monetarisierung nach außen. Keine dieser Verwendungen meint eine KI-Klasse, die aus dem Wissen und dem Netz eines Experten lernt. Der Anspruch dieses Papers ist deshalb eng gefasst: Es ist nach Kenntnis des Autors die erste Beschreibung dieser Klasse unter diesem Namen. Die Teile sind bekannt. Die Verbindung und ihr Name sind es nicht. Der Name soll außerdem dazu beitragen, dass sich dieses Wissen und die Möglichkeiten, die darin liegen, herumsprechen, kritisch diskutiert und weiterentwickelt werden.

4 · Die Daten

Ein LHNM steht und fällt mit seiner Datenbasis, und es lohnt sich, genau zu sagen, worin sie sich von dem unterscheidet, was sonst als Daten gehandelt wird. Vier Quellen fließen zusammen.

Erstens, die Korrespondenz. Über Jahrzehnte sammeln sich bei einem Experten, einem Team oder einem Haus mehrere hunderttausend Nachrichten und Anhänge. Sie enthalten nicht Adressen, sondern Vorgänge: wer wen wann mit welcher Bitte angesprochen hat, was daraus wurde, wer geantwortet hat und wer nicht, wer ein Angebot abgelehnt hat und warum. Das ist die Chronik eines Netzes, und sie lässt sich normalerweise weder erwerben noch für ein Training nutzen.

Zweitens, die strukturierten Bestände: Kontaktdatenbanken, über Jahre gepflegte Tabellen, im zugrunde liegenden Fall zu Family Offices, Familien, Familienbeziehungen, Stiftungen, Unternehmen, Ankaufsprofilen, Finanzierungspartnern und zu privatem Vermögen, oft halbfertig, oft veraltet, aber mit einem Altersstempel je Zeile, der selbst eine Information ist. Vieles davon ist proprietäres Wissen, das sich mit allem Geld der Welt nicht in einem Monat nachholen ließe, weil die Wissensträger ihr Wissen zum großen Teil ausdrücklich nicht öffentlich teilen und es deshalb nirgends ausgelesen werden kann. Diese Art von Wissen, meist die unteren beiden Schichten des Eisbergs, existiert in vielen Branchen in ähnlicher Form. Das Muster ist branchenunabhängig; was es braucht, ist der Experte, der die Bestände lesen kann. Ohne ihn sind Wert und Qualität eines LHNM von Anfang an stark gemindert.

Drittens, das dokumentierte Fachwissen des Experten, des Teams und des Hauses: eigene Forschung, eigene Paper, dokumentierte Erfahrungen, Regelwerke, Modelle darüber, warum eine vermögende Familie etwas kauft, warum sie nie kauft oder warum sie in bestimmte Dinge investiert, wie Entscheidungen in Eigentümerkreisen fallen, welche Muster einem Scheitern vorausgehen. Dieses Wissen übersteigt in seiner Domäne häufig das, was an Hochschulen gelehrt und in Studien veröffentlicht wird, und zwar nicht, weil die Forschung schlecht wäre, sondern weil sie von außen beobachtet. Wer seit zwanzig Jahren mit den Familien verhandelt, reist und investiert, kennt den Teil des Eisbergs unter der Wasserlinie. Das gilt in anderen Domänen ebenso: Die besten Produzenten, Chirurgen oder Verhandler der Welt lehren in der Regel nicht an Universitäten und geben ihr Wissen deshalb auch nicht an Studenten weiter, die es weiterentwickeln könnten. Man lernt über sie aus zweiter Hand. Entscheidend ist: Dieses Wissen wird nicht veröffentlicht und kann deshalb auch nicht in das Training von Sprachmodellen einfließen.

Viertens, das Erfahrungswissen, das erst beim Aufbau ausgesprochen wird. Ein großer Teil dessen, was einen Experten ausmacht, steht nirgends, auch nicht in seinen

eigenen Dateien. Es kommt erst heraus, wenn er Fälle diktiert, diskutiert, Entscheidungen begründet, Regeln formuliert und Fehlurteile protokolliert. Dieser Teil ist der wertvollste und der mühsamste, ähnlich wie am Anfang beim Aufbau der Sprachmodelle. Dass Sprachmodelle genau hier zum ersten Mal helfen, weil sie Teile dieses Wissens aus dem Verhalten eines Experten herausholen können, wurde in Abschnitt 3 gezeigt; in einem LHNM wirkt das in beide Richtungen: Die Maschine lernt vom Experten und hilft ihm zugleich, auszusprechen, was er weiß.

Fünf Eigenschaften unterscheiden diese Daten von dem, was Datenhändler verkaufen. Sie sind nicht öffentlich: Kein Teil davon wurde je automatisiert ausgelesen, weil er nie im Netz stand. Sie sind longitudinal: Sie zeigen Beziehungen über Jahre, nicht Zustände zu einem Stichtag. Sie sind relational: Ihr Wert liegt in den Verbindungen zwischen den Einträgen, nicht in den Merkmalen der einzelnen Einträge. Ein Beispiel macht den Unterschied deutlich: Die Datenhändler zählen weltweit rund 510.000 Personen mit einem Vermögen über 30 Millionen US-Dollar,[50] und eine solche Liste kann man kaufen. Sie sagt, wer reich ist. Sie sagt nicht, wer mit wem Geschäfte macht, wer wem vertraut, wer wen nie wieder anruft und wer zu wem Zugang hat oder ihn herstellen kann. Das erste ist eine Tabelle, das zweite ein Netz. Sie sind motivhaltig: Sie enthalten, warum jemand handelt, und damit das, was Behavioral Finance für Märkte beschreibt, für einzelne Entscheider. Und sie haben eine Herkunft: Jeder Eintrag weiß, woher er stammt und wie alt er ist.

Die Soziologie hat die Mechanik solcher Netze lange vor der KI beschrieben. Mark Granovetter zeigte 1973, dass die entscheidenden Informationen über schwache Verbindungen fließen, nicht über enge,[51] und Ronald Burt, dass derjenige Vorteile erzielt, der strukturelle Löcher zwischen sonst getrennten Gruppen überbrückt.[52] Ein Experte mit Jahrzehnten an Zugang sitzt in Hunderten solcher Löcher. Toby Stuart hat 2025 ergänzt, dass Status durch Salbung entsteht: Wer von einem hochrangigen Verbinder vorgestellt wird, wird von der Gegenseite anders gelesen.[53] Ein LHNM macht diese drei Effekte zum ersten Mal abfragbar, ohne sie zu verbrauchen.

5 · Aufbau

Die Architektur eines LHNM folgt aus einem einzigen Grundsatz: Die Rohdaten verlassen den eigenen Tresor nie, und nach außen gehen nur Antworten und Türen. Alles Übrige ist die Konsequenz daraus (Abb. 5).

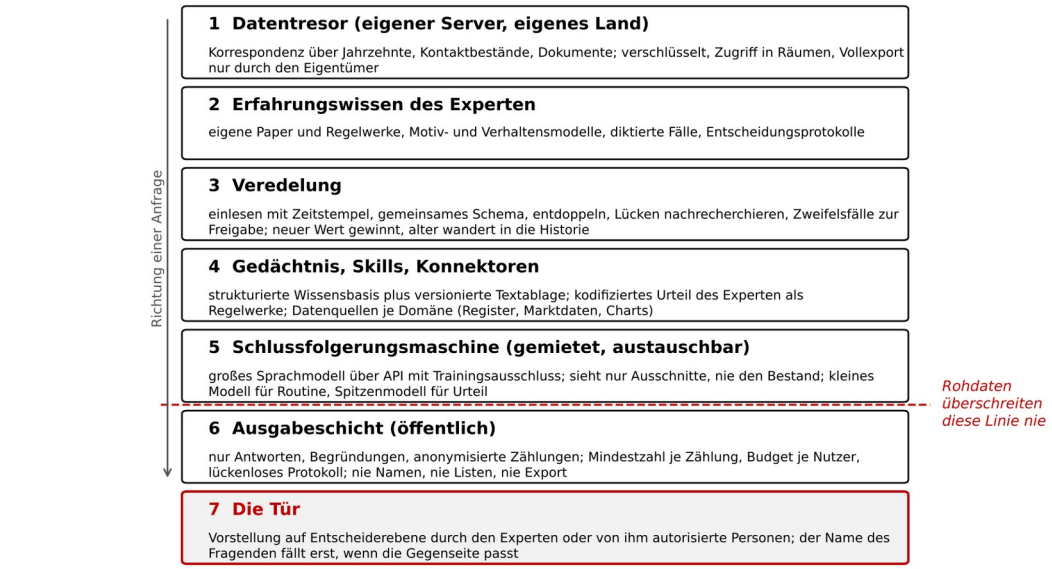

Quelle: eigene Darstellung nach dem beschriebenen Fall.

© 2026 David A. Pieper

Abb. 5: Schichten eines Large Human Network Models. Eigene Darstellung nach dem beschriebenen Fall. © 2026 David A. Pieper.

Die unterste Schicht ist der Datentresor: ein eigener Server im eigenen oder in einem bewusst gewählten Rechtsraum, verschlüsselt, mit Zugriff nach Räumen statt nach Einzelrechten. Wer im Haus mitarbeitet, darf einbringen, aber nicht abziehen; ein Vollexport ist nur dem Eigentümer möglich, und jeder Zugriff wird protokolliert, mit Alarm bei Massenabruf. Darüber liegt das Erfahrungswissen des Experten in dokumentierter Form. Die Veredelungsstrecke macht aus beidem eine Wissensbasis: einlesen mit Zeitstempel, gemeinsames Schema, entdoppeln, Lücken über Konnektoren nachrecherchieren, Zweifelsfälle zur Freigabe vorlegen. Ein neuer Wert gewinnt, der alte wandert in die Historie.

Die vierte Schicht ist das, was die Maschine tatsächlich liest: eine strukturierte Wissensbasis für Filterbares, eine versionierte Textablage für Thesen, Fälle und Regeln, die kodifizierten Urteile des Experten als ausführbare Regelwerke (im Sprachgebrauch der Werkzeuge: Skills) sowie die Konnektoren und Schnittstellen zu den Datenquellen der jeweiligen Domäne, darunter besondere Datenlieferanten, die für das einzelne LHNM von zentraler Bedeutung sind und die der Autor hier bewusst nicht vollständig aufzählt. Im beschriebenen Fall gehören zum Beispiel Handelsregister, Gesellschafterdaten und Marktdaten dazu. Beim Musikproduzenten wären es die Charts der Streamingdienste, beim Filmproduzenten Besetzungs- und Rechtedatenbanken, beim Chirurgen die eigene Fallsammlung, in technischen Domänen auch Patentdatenbanken. Diese Quellen reichern das Modell an und machen es teils erst wirksam, und auch sie sind nicht frei zugänglich: Die Daten hinter solchen Schnittstellen sind lizenziert, begrenzt und teuer. Der Fall LinkedIn zeigt, wie hart diese Grenze verteidigt wird: Das Netzwerk geht seit Jahren gerichtlich gegen das Auslesen seiner Profile vor und öffnet seine Schnittstellen nur wenigen Partnern, aus genau dem Grund, um den es in diesem Paper geht.[54]

Die fünfte Schicht ist die Schlussfolgerungsmaschine: ein oder mehrere große Sprachmodelle, angebunden über eine Schnittstelle mit vertraglichem Trainingsausschluss. Sie sehen nur die Ausschnitte, die eine Anfrage braucht, nie den Bestand. Diese Schicht lässt sich auch mit offenen Modellen betreiben, wenn man aus

Gründen des Datenschutzes und der Diskretion gar nichts nach außen geben will, um den Preis, auf das gerade leistungsstärkste Modell und auf einen Teil von Komfort und Umsetzbarkeit zu verzichten. Die Modelle sind austauschbar, und das ist Absicht: Routinearbeit erledigen kleine, billige Modelle; die anspruchsvollen Schlüsse bekommt das stärkste, das nebenbei von Jahr zu Jahr besser wird. Der Anbieter kann wechseln, ohne dass sich am LHNM etwas ändert. Wer den Anbietern nicht traut, kann diese Schicht wie beschrieben mit einem offenen oder einem im eigenen Rechtsraum akzeptierten Modell auf dem eigenen Server betreiben; angesichts der weltweiten Blockbildung wird das für manche Häuser keine Frage des Geschmacks sein.

Oberhalb der roten Linie liegt die Ausgabeschicht. Sie kennt keine Namen. Sie liefert Einordnungen, Begründungen und anonymisierte Zählungen („14 Familien im Bestand passen zu diesem Anliegen, aus drei Gründen“), mit einer Mindestzahl je Zählung, einem Budget je Nutzer und einem lückenlosen Protokoll. Nie Namen, nie Listen, nie Export. Dann erst kommt die Tür: Die Vorstellung, die Brücke in die menschliche Welt, erfolgt persönlich, auf Entscheiderebene, durch den Experten oder von ihm autorisierte Personen, und der Name des Fragenden fällt erst, wenn die Gegenseite passt.

Diese Trennung ist nicht nur Sicherheit, sie ist Datenschutz als Architektur. Ein LHNM verarbeitet Daten Dritter, die nicht selbst gefragt wurden. Ein System, das keine Rohdaten herausgibt und keine Listen erzeugt, ist dafür in jeder Rechtsordnung der tragfähige Ausgangspunkt; in der Europäischen Union kommen Rechtsgrundlage, Informationspflichten und Auskunftsrechte hinzu, die vor dem Betrieb anwaltlich zu klären sind.[55] Eine Bemerkung dazu ist nötig, weil dieses Paper nicht für einen Rechtsraum geschrieben ist. Modelle dieser Art können zum Wissens- und Technologievorsprung einer Region oder ganzer Branchen beitragen, gerade dort, wo das wertvollste Wissen zum Beispiel in Familienunternehmen und bei einzelnen Köpfen liegt. Eine Regulierung, die schon den Aufbau erschwert, würde diesen Vorsprung nicht schützen, sondern verlagern: Das Geschäft entstünde dann dort, wo es erlaubt ist, so wie es heute bereits geschieht. Für World Models gilt dasselbe: Wo jeder Beschäftigte, der einem Roboter eine Bewegung vorführt, vorher eine Einwilligung unterschreiben muss und die Aufnahmen nicht gespeichert werden dürfen, entstehen diese Modelle in den Ländern, die zuerst Fortschritt zulassen und dann regulieren.

6 · Wie Experten ihr Large Human Network Model aufbauen

Das Wort „trainieren“ wird hier bewusst vorsichtig gebraucht. Ein Experte oder ein Team von Experten, das sein LHNM aufbaut, trainiert keine Gewichte im Sinne eines Sprachmodells. Es setzt die Gewichte des Netzes (Abschnitt 3) und tut etwas, das diffiziler ist: Es bringt sein Wissen in eine Form, die eine Maschine lesen, prüfen und anwenden kann. Technisch besteht das aus Retrieval (die Maschine findet die passenden Ausschnitte), Gedächtnis (sie behält, was sie gelernt hat), Werkzeuggebrauch (sie fragt Konnektoren ab) und prozeduralen Anweisungen (sie befolgt die kodifizierten Regeln). Ein Fine-Tuning des Sprachmodells auf dem eigenen Korpus ist eine Option für später, kein Teil des Grundaufbaus. Der Aufbau verläuft in fünf Stufen.

Erstens, einlesen. Alles, was es gibt, kommt mit Zeitstempel in den Tresor: Korrespondenz, Bestände, Dokumente, Fotos von Visitenkarten, Notizen. Nichts wird am Original aufgeräumt; sortiert wird die Kopie.

Zweitens, strukturieren. Die Veredelungsstrecke zieht aus dem Rohmaterial Personen, Häuser, Beziehungen und Vorgänge, entdoppelt sie und legt zu jedem Eintrag Quelle und Datum ab. Das ist Rechenarbeit, überwiegend von kleinen Modellen, und sie dauert Wochen.

Drittens, Erfahrungswissen herausholen. Das ist die eigentliche Arbeit des Experten. Er diktiert Fälle, begründet Entscheidungen, benennt Muster, formuliert, was er auf den ersten Blick sieht und warum. Im beschriebenen Fall sind so über mehrere hundert Arbeitsstunden zum Beispiel Regelwerke für das Zusammenführen von Objekt und Käufer, für die Prüfung eines Gegenübers, für die Motive von Familien und Family Offices und für den Umgang mit Anfragen entstanden. Ein erfahrener Chirurg würde das Gleiche mit Tausenden Fällen tun: Welche Nase passt zu welchem Gesicht, welche Erwartung ist unrealistisch, welcher Patient sollte nicht operiert werden. Was ein Praktiker nach drei Datenpunkten und zwei Telefonaten weiß, muss hier Satz für Satz ausgesprochen werden, damit die Maschine es lernen kann.

Viertens, Urteil als Regel kodifizieren. Aus den diktierten Fällen werden ausführbare Regelwerke: Ein Ankaufsprofil ist die Hauptrichtung, aber kein Ausschlusskriterium; ein Vermittler kommt nur über den Eigentümer; eine Zählung unter drei Treffern wird nicht angezeigt. Diese Regeln sind das, was die Maschine vom Experten lernt, und sie sind proprietär. Das Verfahren selbst ist wieder branchenunabhängig; die Regeln sind es nicht.

Fünftens, prüfen und nachsteuern. Das Modell wird an Schattenfällen gemessen: Hätte es die Käufer gefunden, die der Experte gefunden hat? Jede Entscheidung wird protokolliert, mit dem Ergebnis Monate später, und ein Protokoll „wer hatte recht“ zeigt, wo das Urteil des Experten und das der Maschine auseinanderliegen. Die Zielgröße im beschriebenen Fall ist eine Trefferquote von 90 bis 95 Prozent bei Vorschlägen, weil ein falscher Vorschlag in dieser Welt mehr kostet als ein ausgelassener.

Was dabei an Produktivität entsteht, lässt sich heute nur schätzen, aber die Richtung ist klar. Im beschriebenen Fall übernimmt die Maschine die Vorarbeit, die in einem klassischen Beratungshaus ein Team aus Analysten, Assistenten und Vertrieb leistet: suchen, prüfen, abgleichen, ansprechen, nachfassen, dokumentieren. Nach Einschätzung des Autors entspricht das, bei richtiger Umsetzung, der Arbeit von 20 bis 30 Festangestellten, mit dem Unterschied, dass die Maschine jede Anfrage gegen den gesamten Bestand prüft und nicht gegen das, was ein Mitarbeiter gerade im Kopf hat. Ein Haus mit wenigen Köpfen kann damit die Arbeit einer deutlich größeren Organisation leisten. Das ist eine Schätzung aus der Praxis, kein Messwert; sie wird in Abschnitt 11 als Hypothese formuliert, und der Engpass bleibt der Experte selbst, worauf Abschnitt 10 zurückkommt.

Wer außerdem trainiert

Ein LHNM lernt nicht nur von seinem Eigentümer. Je nach Modell tragen alle bei, die es benutzen. Im Fall eines Netzes aus Familien und Family Offices lernt das Modell aus jedem Anliegen, was gerade gesucht wird, aus jeder Vorstellung, wer zu wem passt, und aus jedem Ergebnis, ob das Urteil stimmte; Mitglieder eines geschlossenen Kreises bringen zusätzlich eigene Kontakte ein. In einem Ministerium würden alle Mitarbeiter einpflegen, was sie wissen, und das Haus behielte, was heute mit jedem Wechsel verloren geht. Gerade für staatliche Organisationen liegt darin ein Potenzial, das bisher kaum gesehen wird. Beim Chirurgen wären es die Fälle der Patienten, mit deren Einwilligung. Das ist ein Datennetzwerkeffekt im engen Sinn: Jeder Nutzer

macht das Modell für den nächsten besser, ohne dass jemand die Daten eines anderen sieht. Die Datenschranke bleibt dabei absolut: Was ein Nutzer eingibt, verbessert das Modell, aber der Eigentümer verwendet es nie für eigene Geschäfte gegen den Nutzer, etwa um ein Anliegen selbst zu verfolgen, bevor er es vermittelt.

7 · Betrieb

Eine Anfrage an ein LHNM läuft in sechs Schritten (Abb. 6). Der Fragende beschreibt sein Anliegen in eigenen Worten. Die Maschine ordnet es ein, liefert Kontext und stellt eine Rückfrage. Sie gleicht es gegen Netz und Wissen ab und meldet anonymisiert, ob und wie viele passende Menschen es gibt und aus welchen Gründen. Bis hierhin vergehen Minuten, und bis hierhin ist der Experte nicht beteiligt. Dann folgt sein Urteil: Ist das Anliegen tragfähig, was muss vorher geklärt werden, in welcher Reihenfolge wird angesprochen? Dann die Tür, und zuletzt das Ergebnis, das zurück ins zentrale Gedächtnis fließt.

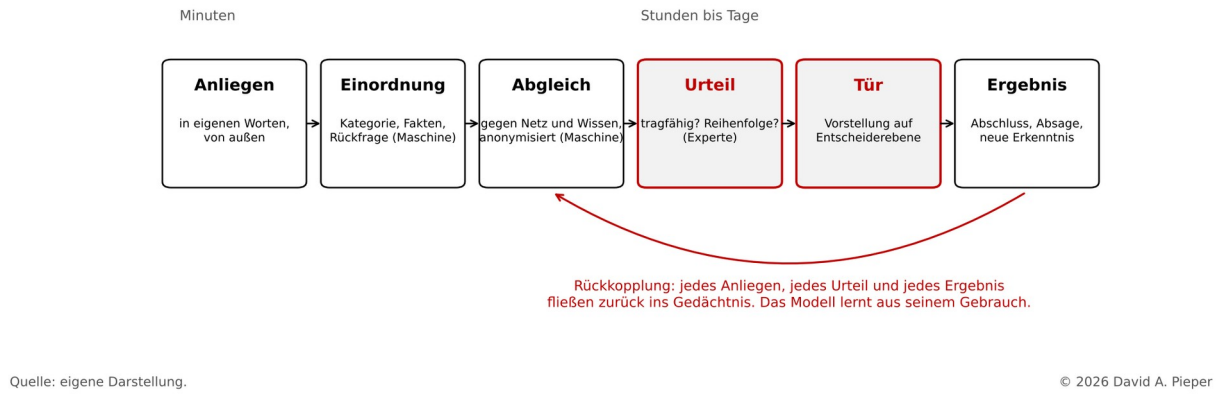

Abb. 6: Weg einer Anfrage durch ein Large Human Network Model und Rückkopplung. Eigene Darstellung. © 2026 David A. Pieper.

Die Reihenfolge ist der Punkt. In der herkömmlichen Arbeitsweise steht der Experte am Anfang: Er nimmt das Gespräch an, recherchiert, denkt nach, telefoniert und sagt dann ab oder zu. Seine Zeit geht in die Vorarbeit, und davon ist der größte Teil vergeblich. In einem LHNM steht er am Ende. Die Maschine übernimmt das Sammeln, Sichten und Vorsortieren, und der Experte urteilt nur noch über das, was die Prüfung bestanden hat. Automatisiert wird das Sammeln, nicht das Urteilen. Das ist der Unterschied zwischen einem Berater, der skaliert, und einem, der sich vervielfältigen müsste, und es gilt nicht nur für Berater, sondern für jede Funktion, deren Tag aus Vorarbeit besteht: Vertrieb, Marketing, Finanzierung, Einkauf, Personal. Das Modell bleibt aktuell, weil seine Träger es täglich füttern, von jedem Gerät aus, im Vorbeigehen: Ein Vertriebskanal in einem Land funktioniert nach einem Regierungswechsel nicht mehr, ein Zulieferer hat geliefert, eine Familie hat verkauft. Wer neu in den Kreis der Beitragenden kommt, bringt sein Wissen mit; wer ausscheidet, verliert den Zugang. Was er eingebracht hat, bleibt, und genau daran hängt die Eigentumsfrage, auf die Abschnitt 9 zurückkommt.

Im beschriebenen Fall hat ein geschlossener Funnel die Rolle, diesen Unterschied nach außen durchzusetzen: Es gibt keinen anderen Weg zum Experten als durch das System, jede Anfrage hat einen Preis, nach außen in Geld, nach innen als Kontingent, und eine Ablehnung kostet den Fragenden nichts. Nach innen, in der Familie oder im Unternehmen, hätte beispielsweise jeder Mitarbeiter ein festes Kontingent an Anfragen. Der Wert liegt dabei in drei Dimensionen. Erstens die Zeit: Antworten, die

sonst Tage brauchen, kommen in Minuten. Zweitens die Möglichkeit: Ohne das Wissen des Modells hätte der Fragende die Anfrage womöglich gar nicht stellen können, weil er nicht wusste, wer zu wem passt. Drittens der Einsatz: In den unteren Schichten des Eisbergs ist der Wert einer Information sehr hoch, zuweilen entscheidend, weil sie zu Aufträgen in Millionenhöhe führt, gesamtwirtschaftlich wiegt oder, in Medizin, Verteidigung und nationaler Sicherheit, über Leben und Tod entscheidet. Das Ergebnis kann eine Präzision und Geschwindigkeit sein, die es in dieser Welt bisher nicht gab: Ein Family Office und eine Privatbank werden innerhalb von Minuten als passend erkannt, oder eine sonst unzugängliche Information steht in Sekunden oder in weniger als einer Stunde zur Verfügung, und sie kann, wie oben beschrieben, Millionen wert sein. Die Öffnung dieser Schicht des Eisbergs kann bei denen, die sie zum ersten Mal erleben, einen ähnlichen Effekt auslösen wie seinerzeit die Veröffentlichung von ChatGPT.

8 · Übertragbarkeit

Das Muster ist nicht an Family Offices gebunden. Es passt auf jede Domäne, in der vier Bedingungen zusammenkommen: Das entscheidende Wissen ist nicht öffentlich und wird es nicht; es liegt bei wenigen Menschen mit Jahrzehnten an Zugang; die Entscheidungen, um die es geht, sind groß genug, dass Zugang einen Preis hat; und es gibt Nachfrage von außen oder innerhalb der Organisation, die diesen Preis zahlt.

Einige Beispiele machen das anschaulich. Ein Filmproduzent, der seit vierzig Jahren zu den am besten vernetzten Personen seiner Branche gehört, weiß, welcher Regisseur mit welchem Darsteller nie wieder arbeitet, welcher Verleih welche Stoffe kauft, wie Verträge tatsächlich verhandelt werden und wer bei welchem Sender entscheidet. Sein LHNM bestünde aus Tausenden Dateien und Vorgängen und aus seinen menschlichen Beziehungen, von denen keine Teil eines Sprachmodells ist. Ein Musikproduzent weiß, wie Künstler entstehen, wie man Veranstalter bewegt, welche Verträge welche Karrieren gemacht oder beendet haben. Ein Risikokapitalgeber der ersten Reihe weiß über Hunderte Beteiligungen, Gründer und Mitinvestoren mehr als jede Datenbank; weltweit prägen vielleicht zwanzig solcher Häuser den Markt, und ihr Wissen ist der Grund dafür.

Der plastische Chirurg ist das Beispiel, an dem sich Chancen und Grenzen zugleich zeigen. Einer der besten seines Fachs könnte aus Tausenden Fällen, Beratungsgesprächen und Bildern ein Modell aufbauen, das einem Patienten vor dem ersten Termin sagt, was in seinem Gesicht möglich ist, was er nicht tun sollte und wie das Ergebnis aussähe, und das ihn, wenn der Eingriff nicht zu diesem Operateur passt, an den Kollegen weiterreicht, der ihn besser operieren kann. Das ist ein LHNM im vollen Sinn: Wissen, Urteil, Netz und Tür. Es kann je nach Zweckbestimmung ein Medizinprodukt und damit in der Europäischen Union ein Hochrisiko-System nach der KI-Verordnung sein,[56] mit allem, was daran hängt. Regulierte Domänen brauchen eine zusätzliche Schicht aus Zulassung, Haftung und ärztlicher Letztverantwortung. Das spricht nicht gegen das Modell, es bestimmt, wer es bauen darf, und es ist ein Hinweis an die Politik, Innovation mit Augenmaß zu regulieren.

Drei Spielarten: die Koryphäe, die Familie, das Unternehmen

Ein LHNM kann in drei Spielarten betrieben werden, und die Architektur ist in allen dieselbe. Die erste ist die Spielart nach außen: Eine Koryphäe macht ihr Wissen und ihr Netz für zahlende Dritte zugänglich, so wie es der beschriebene Fall tut. Die zweite ist die interne Nutzung: Ein Haus baut sein eigenes Modell und fragt es nur

selbst. Für Unternehmerfamilien und Family Offices ist das womöglich die wichtigere Spielart. Ihr Wissen liegt verstreut: beim Patriarchen, bei zwei langjährigen Beratern, im Family Office an einem anderen Ort, in Beteiligungen auf drei Kontinenten, in den Köpfen von Menschen, die mit der nächsten Generation nicht mehr sprechen werden. Mit jedem Generationswechsel geht ein Teil davon verloren. Ein internes LHNM hält dieses Wissen im Haus, macht es abfragbar und übergabefähig, ohne dass es an einen Dienstleister gehen muss.

Die dritte Spielart ist das Unternehmen, und sie ist die größte. Was Unternehmen heute „interne KI“ nennen, ist fast immer ein Sprachmodell über den eigenen Servern: Warenwirtschaft, Laufwerke, Verträge, Tickets, Mails. Das ist nützlich, aber es ist ein Sprachmodell nach innen. Es erschließt, was das Unternehmen geschrieben hat, nicht, was es weiß. Ein öffentliches Beispiel macht das anschaulich. Das Familienunternehmen STIHL, 1926 gegründet und heute in mehr als 160 Ländern vertreten,[57] verdankt seinen Vorsprung nicht dem ERP-System. Sein Vorstandsvorsitzender hat im Oktober 2026 in einem Interview beschrieben, woraus er stattdessen besteht: Das Unternehmen habe als Familienunternehmen „nicht ständig den Kapitalmarkt im Nacken“ und müsse seine Strategie nicht korrigieren, wenn es einmal schlechter laufe; nicht die Technik bestimme, sondern der Kunde; beim Fachhandel sei man „fast religiös“; und der Chef des US-Geschäfts sei ausgetauscht worden, weil er „ein anderes Spiel spielen“ wollte.[58] Keiner dieser Sätze steht in einem System. Jeder von ihnen entscheidet, was das Unternehmen tut. Der Vorsprung liegt beim Chefentwickler, der weiß, warum eine Toleranz gilt und wann man sie brechen darf; beim Vertriebsleiter, der den Einkaufsleiter des Kunden seit fünfzehn Jahren kennt; bei der Inhaberfamilie, die mit dem Zulieferer in Asien per Handschlag arbeitet; beim Wirtschaftsprüfer, der weiß, wie die Geschäfte tatsächlich strukturiert werden; bei der Managerin, die die Expansion in ein Land gemacht hat und die Mittelsmänner vor Ort kennt. In einer Organisation mit tausend Beschäftigten sind das vielleicht dreißig Menschen, und ihr Wissen ist zugleich das wertvollste und das am wenigsten gesicherte Vermögen der Firma. Ein Unternehmens-LHNM ist das Gedächtnis dieser dreißig: ihr Wissen und ihr Netz, strukturiert, mit Herkunft und Zeit, nach Räumen selektiv ausgespielt, täglich von ihnen selbst aktuell gehalten. Es ist der Brain Trust des Hauses,[59] nur dass er Tag und Nacht abfragbar ist und nicht mit dem Gründer in den Ruhestand geht.

Drei Einwände liegen nahe, und sie wiegen unterschiedlich schwer. Der erste ist der ernste: Wissen ist in Firmen Macht. Wer sein Wissen in ein System gibt, gibt einen Teil seiner Stellung ab, und daran ist das Wissensmanagement der 1990er Jahre gescheitert, nicht an der Technik. Die Antwort kann nur im Eigentum oder in anderen Formen der Beteiligung liegen: Wer beiträgt, wird am Modell beteiligt, etwa über eine eigene Anteilsklasse, die mit dem Wert des Modells wächst und an die Mitwirkung gebunden ist. Für Familienunternehmen mit Beschäftigten, die zwanzig oder dreißig Jahre im Haus sind, ist das nahe an dem, was sie ohnehin leben. Der zweite Einwand ist die Mitbestimmung und der Schutz der Beschäftigtendaten, der in Europa strenger ist als anderswo; das ist eine Architekturfrage von Anfang an, kein Grund, das Modell nicht zu entwerfen. Der dritte Einwand lautet, dass ein Modell, das die Kronjuwelen bündelt, das attraktivste Ziel für Spionage schafft, das die Firma je hatte. Er wiegt aus Sicht des Autors am wenigsten. Die Welt bewahrt seit Jahrzehnten Rezepturen, Konstruktionspläne und Waffencodes, die nicht täglich gestohlen werden. Ein LHNM, das nichts exportiert, in Räumen arbeitet, jeden Zugriff protokolliert und bei Massenabruf Alarm schlägt, ist leichter zu schützen als die tausend Laptops, auf denen dasselbe Wissen heute verstreut liegt. Das heißt nicht, dass Sicherheit

nachrangig wäre, im Gegenteil: Die Angreifer werden mit den Sprachmodellen besser, und Quantenrechner stehen vor der Einführung. Aber es ist lösbar, und es sollte vom Bau nicht abhalten.

Werte als Parameter

Das STIHL-Beispiel zeigt etwas, das über das Wissen einzelner Personen hinausgeht und das bisher kein System aufnehmen konnte: die Werte eines Hauses. Jede Unternehmerfamilie hat über Generationen oder Jahrzehnte ein Verständnis davon entwickelt, wie sie Geschäfte macht und wie nicht, mit wem, zu welchen Bedingungen, was sie nie tun würde, auch wenn es sich rechnet, und was sie immer tut, auch wenn es sich nicht rechnet. Das ist die Kern-DNA der meisten Familien, und sie steht in keinem ERP-System, keinem CRM und keiner anderen Software, weil diese Systeme Vorgänge verwalten und keine Haltung. Sie steht, wenn überhaupt, in der Familienverfassung, in der Satzung einer Stiftung oder in den Köpfen der Gesellschafter.[60] Ein LHNM ist das erste System, in das sich diese Werte unmittelbar einbauen lassen, und zwar als Parameter im Sinne von Abschnitt 3: als gesetzte Gewichte, die bestimmen, welche Gegenüber überhaupt infrage kommen, welche Wege das Modell vorschlägt und welche nicht, in welcher Reihenfolge angesprochen wird und wann eine Anfrage abgelehnt wird, obwohl sie Geld brächte. Eine Familie, die seit drei Generationen nicht an Finanzinvestoren verkauft, nicht mit bestimmten Ländern handelt oder ihre Lieferanten nicht gegeneinander ausspielt, kann das dem Modell sagen, und das Modell handelt danach, bei jeder Anfrage, ohne dass ein Mitarbeiter es jedes Mal neu erklären muss. Dasselbe gilt für andere Branchen und für staatliche Akteure mit ihrem jeweiligen Wertekanon.

Das macht ein LHNM zu der Brücke, die in der Family-Office-Welt bisher fehlt: zwischen der Familie, ihrem Family Office, dem laufenden Unternehmen, den Mitarbeitern und, wo die Familie es will, der Öffentlichkeit. Diese Sphären folgen verschiedenen Logiken und werden von verschiedenen Menschen betrieben; was sie verbindet, sind die Werte der Familie, und genau die ließen sich bisher nur über Personen weitergeben. Ein Modell, das diese Werte als Parameter enthält und zugleich das Wissen und das Netz aller Sphären, ist das erste gemeinsame Gedächtnis dieser Beteiligten, und es ist der Ort, an dem eine Familie festlegen kann, wofür sie Maschinen einsetzt und wofür nicht. Das Paper „Old Money, New Machines“ des Autors behandelt diese Frage aus Sicht der Familien; dieses Paper liefert dafür das Werkzeug.[60]

Dazu kommt ein Punkt, der in Europa Gewicht hat. Die großen Sprachmodelle haben die Werte ihrer Erbauer in sich. Eine Untersuchung von 2024 hat gezeigt, dass ihre Antworten auf den Werteskalen des World Values Survey am nächsten bei den englischsprachigen und protestantisch-europäischen Ländern liegen,[61] und die chinesischen Modelle sind in anderer Richtung geprägt. Wer ein Sprachmodell mietet, mietet diese Prägung mit. Für ein Familienunternehmen in Oberösterreich oder Nagano ist das in vielen Fragen nicht die Haltung, mit der es Geschäfte machen will. Ein LHNM ändert am Sprachmodell nichts, aber es setzt eine Schicht darüber, in der die Werte des Hauses den Ausschlag geben, nicht die des Anbieters. Das ist, soweit der Autor sieht, der einzige Weg, auf dem eine Organisation heute ihre eigene Haltung in ein KI-System bekommt, ohne ein Modell zu trainieren.

Hochsensible Domänen

Es liegt nahe, LHNMs dort zu sehen, wo Wissen offen gehandelt wird. Der größere Nutzen liegt aber wahrscheinlich dort, wo es das nie wird: in Domänen, die diskret,

geschützt und mission-critical sind. Medizin, Verteidigung, Diplomatie, Ministerien, große private Vermögen. In all diesen Bereichen existiert einzigartiges Wissen über Menschen, Verbindungen und Zugänge, das weder veröffentlicht noch an Nachfolger übergeben wird und das mit jeder Pensionierung, jedem Wechsel und jedem Todesfall verloren geht. Wer ein Rüstungsunternehmen führt, wer eine Botschaft leitet, wer ein Ministerium seit zwanzig Jahren kennt, verfügt über ein Netz, das keine Organisation besitzt, sondern nur die Person. Ein LHNM ist die erste Form, in der ein solches Netz im Haus bleiben kann, ohne dass es jemand herausgeben muss. Dass es sich gerade für diese Bereiche eignet, folgt aus seiner Architektur: Es gibt nichts heraus.

Für wen das Modell ist

Ein LHNM ist ein Werkzeug für die Spitze eines Fachs, und es ist wichtig, das ohne Überheblichkeit zu sagen. Es trainiert keinen Nachwuchs und befähigt nicht die dritte Reihe eines Hauses; dafür gibt es andere Werkzeuge. Es kodiert das Wissen derer, die in ihrem Gebiet den Unterschied machen: Entscheider, Meister ihres Fachs, Personen, auf deren Namen hin Türen aufgehen. Von ihnen gibt es insgesamt erstaunlich viele, in jeder einzelnen Branche aber nur wenige, und jede dieser Personen ist ein Knotenpunkt, über den andere erst handlungsfähig werden. Für sie ist das Modell gedacht, und für die, die mit ihnen ins Geschäft kommen oder ihre Strukturen verbessern wollen.

9 · Wirkung

Was ändert sich, wenn Experten ihre Netze in Modelle fassen? Die Antwort hat mehrere Seiten, und sie werden hier nacheinander aufgeführt.

Für den Wissensträger

Für den Wissensträger wird zum ersten Mal ein Vermögen bewertbar und übertragbar, das bisher mit ihm starb. Das Wissen und das Netz einer Koryphäe sind heute ihr größter Besitz und zugleich ihr flüchtigster: Sie lassen sich nicht übertragen, nicht teilen, nicht verkaufen und nicht vererben; eine ernste Krankheit setzt ihren Wert auf null. Ein LHNM konserviert dieses Vermögen, macht es skalierbar, analysierbar und erweiterbar, und es macht es übergabefähig. Für Familienunternehmen und Häuser mit Nachfolgefrage ist das kein Nebeneffekt, sondern der Kern. Für den Experten selbst heißt es, dass seine Zeit nur noch in das Urteil fließt und seine Erfahrung mit jeder Anfrage wächst, statt mit jeder vergeblichen Vorarbeit zu verschleißen. Das alles am Anfang einer Entwicklung, in der KI, Robotik und Quantenrechner noch jung sind; was ein solches Modell in zehn Jahren leisten kann, lässt sich heute nicht seriös beschreiben.

Für den Nutzer

Für den Nutzer ändert sich, was er bekommt. Datenbanken verkaufen Zahlen, Expertennetzwerke verkaufen Gespräche, Sprachmodelle verkaufen Text. Ein LHNM führt zum Ergebnis: zum Kapital, zum Käufer, zum Partner, zum Arzt, der die richtige Entscheidung trifft. Kontakte, die man sonst ein Leben lang nicht erreicht, in Tagen statt Jahren. Das ist der Grund, aus dem ein LHNM einen Preis haben kann, der mit dem Wert der Entscheidung wächst und nicht mit der Zahl der Abfragen. Das verlangt nach innen wie nach außen eine neue Art der Preisbildung, die nicht mehr an den Kosten je Token hängt und deren Folgen heute nicht vollständig absehbar sind.

Für die KI-Wirtschaft

Für die KI-Wirtschaft entsteht eine Schicht, die bisher fehlt. Die Investitionen in Rechenleistung, Modelle und Forschung suchen Anwendungen, die ihren Wert unmittelbar beweisen. Ein LHNM tut das auf beiden Seiten: Der Eigentümer spürt den Nutzen in seinem Geschäft, der Nutzer in seinem Ergebnis. Wo das geschieht, wächst das Vertrauen in die Technik schneller als dort, wo sie Texte zusammenfasst. Für die Agenten, die gerade in die Unternehmen einziehen, ist ein LHNM außerdem die Wissensquelle, die ihnen in geschlossenen Welten fehlt: Ein Agent, der ein LHNM befragen darf, kann dort handeln, wo er heute an der Kante des Plateaus stehen bleibt. Es ist absehbar, dass daraus ein eigener Markt entsteht: Häuser, die Experten beim Aufbau ihres LHNM begleiten, von der Stange für den Standardfall und maßgeschneidert für die Spitze. Dass der Aufbau Monate dauert und Wissen verlangt, das die meisten Wissensträger nicht haben, ist dabei die Eintrittshürde und zugleich der Burggraben dessen, der sie zuerst überwunden hat. Ob sich daraus ein eigenes Produkt entwickeln lässt, ein Modell, das vom ersten Fall gelöst und an andere verkauft wird, so wie NVIDIA seine Plattform für Physical AI an jeden Roboterhersteller verkauft, ist offen und verdient eine kritische Prüfung. Für die Beratungshäuser und die großen Prüfungsgesellschaften wäre ein solches Werkzeug viel wert, ebenso für Technologiekonzerne, die es dem Mittelstand anbieten könnten. Dagegen spricht, was dieses Paper selbst sagt: Übertragbar ist das Schema, nicht der Inhalt, und ohne den Experten, der die Werte setzt und die Tür öffnet, bleibt von einem LHNM eine Datenbank mit guter Oberfläche. Ein Produkt wäre deshalb eher ein Baukasten und eine Begleitung als ein fertiges Modell.

Für Organisationen und Regionen

Für Unternehmen und Organisationen, die über lange Zeit Wissen, Netze und Schutzrechte aufgebaut haben, bedeutet das Modell deshalb mehr als ein weiteres Werkzeug. Es verändert Abläufe (die Vorarbeit wandert zur Maschine, das Urteil bleibt beim Menschen), Produktivität (die Schlüsselpersonen werden befragt, nicht mehr gesucht) und am Ende die Wettbewerbsposition, weil eine Organisation zum ersten Mal mit allem antreten kann, was sie weiß, besitzt, anwendet und kontrolliert, und nicht nur mit dem, was gerade im Raum sitzt. Das gilt in besonderem Maß für Regionen, deren Unternehmen Jahrzehnte oder Jahrhunderte alt sind. Japan zählt rund 46.700 Unternehmen, die älter als hundert Jahre sind;[62] Deutschland hat seine Hidden Champions und Weltmarktführer. Der Vorteil ist allerdings latent, nicht automatisch, und er hat ein Verfallsdatum. In Deutschland sind 57 Prozent der mittelständischen Inhaber 55 Jahre oder älter, bis 2029 stehen rund 545.000 Nachfolgen an, und bis zu 569.000 Unternehmen könnten bis Ende 2029 ohne Nachfolger aufgeben.[63] Dieselben Regionen, die den größten Teil des Eisbergs unter der Wasserlinie besitzen, stehen vor der größten Übergabewelle ihrer Geschichte und gehören zugleich zu den zögerlichsten Anwendern der neuen Technik. Dazu kommt, dass die Produktion selbst abwandert. Nach einer Sonderauswertung der DIHK vom April 2026 planen 43 Prozent der deutschen Industriebetriebe Investitionen im Ausland, 41 Prozent ausdrücklich aus Kostengründen, der höchste Wert seit 2003.[64] Die Familienunternehmen machen da keine Ausnahme: Miele, seit 1899 in Familienhand, verlagert die Waschmaschinenproduktion von Gütersloh nach Polen,[65] und STIHL fertigt seine Akkus in Rumänien und entwickelt seine Rasenroboter in China, weil Deutschland nach den Worten seines Vorstandsvorsitzenden „ein Produktivitätsproblem“ hat und ihm für neue Fertigung im Land „derzeit die Fantasie“ fehlt.[58] Was dabei mitgeht, steht in keiner Bilanz: die Menschen, die wissen, wie die Anlage wirklich läuft, und die Beziehungen, die ein Werk über Jahrzehnte um sich

herum aufgebaut hat. Für diese Regionen ist ein LHNM weniger eine Chance, die sich ergreifen lässt, als ein Fenster, das sich schließt: Was in den kommenden Jahren nicht in ein Gedächtnis kommt, geht mit der Generation. Ein Land, das dieses Wissen besitzt und es nicht festhält, verankert und lebendig hält, hat am Ende weniger als eines, das weniger besitzt und es fasst. Das gilt für jede einzelne Organisation ebenso: Wer sich aus Sorge vor Datenschutz und Aufsicht, aus Mangel an Risikokapital oder schlicht aus Gewohnheit nicht traut und das Fenster verstreichen lässt, verliert nicht nur einen Vorsprung. Er wird von denen verdrängt, die dasselbe Wissen in ihrer Domäne gefasst haben, ob im eigenen Land oder anderswo. Das Wissen schützt den, der es hat, nur so lange, wie niemand sonst es abrufbar macht.

Für den Fall, dass der Ort verloren geht

Eine weitere Wirkung liegt außerhalb des Wettbewerbs. Wissen, das nur in Köpfen, Aktenschränken und lokalen Systemen liegt, ist so verwundbar wie die Menschen und Gebäude, in denen es steckt. Die Ukraine erlebt seit 2022, was das bedeutet: Nach Zählung des UN-Flüchtlingshilfswerks lebten im Februar 2026 rund 5,9 Millionen Ukrainer als Flüchtlinge im Ausland,[66] und mit ihnen verließen Ingenieure, Ärzte, Unternehmer und Verwaltungsfachleute das Land, deren Wissen und Verbindungen dort nun fehlen; was in zerstörten Betrieben, Archiven und Behörden lag, ist teils unwiederbringlich. Die Lage in Europa gilt vielen als unsicherer als zu jedem Zeitpunkt seit dem Ende der Sowjetunion. Ein LHNM mit Sicherungen an mehreren Standorten in verschiedenen Ländern ist in einem solchen Fall das Einzige, was von einem Haus, einer Behörde oder einer Familie übrig bleibt, wenn der Ort verloren geht: nicht die Rohdaten allein, sondern das verknüpfte Gedächtnis dessen, wer was wusste, kannte und entschied. Das gilt am stärksten für die unterste Schicht des Eisbergs: kritische Infrastruktur, Verteidigung, die Zulieferketten der Halbleiterfertigung. Dass die Lithographiesysteme, mit denen die neuesten Chips belichtet werden, mit Lasern des Familienunternehmens TRUMPF aus Ditzingen arbeiten,[67] oder dass japanische Hersteller wie Advantest und DISCO beim Testen und Zerteilen der Wafer kaum zu ersetzen sind, steht in jedem Branchenbericht.[68] Was dort nicht steht, ist das Wissen der Menschen, die diese Anlagen seit Jahrzehnten bauen, einstellen und beliefern, und wer in der Kette wen anruft, wenn etwas ausfällt. Dieses Wissen ist in Europa und Japan zu einem erheblichen Teil in Familienunternehmen zu Hause. Der Punkt, an dem sich die meisten Fachleute einig sind, liegt allerdings in Taiwan: Ein Angriff auf die Insel, bei dem die Fertigungsanlagen zerstört würden und die Menschen, die sie betreiben, ums Leben kämen oder flöhen, würde nicht nur die Produktion der modernsten Chips weltweit zum Stillstand bringen, sondern Wissen vernichten, das sonst kaum existiert. Dieses Wissen ist zugleich das, was ein Staat am wenigsten verlieren darf, und das, was heute am wenigsten gesichert ist. Das ist kein Argument für Furcht, sondern für Vorsorge, und es gilt für Familienunternehmen und Ministerien gleichermaßen.

Eigentum, Bilanz und Beteiligung

Mit der dritten Spielart entsteht ein Vermögensgegenstand, den es bisher nicht gab, und mit ihm Fragen, die noch nicht beantwortet sind. Wem gehört ein Unternehmens-LHNM? Im Familienunternehmen ist die Antwort einfach: der Familie. Sie wird schwieriger, sobald ein Finanzinvestor beteiligt ist, das Unternehmen verkauft wird oder einzelne Beitragende ausscheiden. Was in der Bilanz steht, ist davon unberührt, und das ist der eigentliche Punkt: Nach den internationalen Rechnungslegungsregeln dürfen selbst geschaffene Kundenlisten und vergleichbare Werte nicht als Vermögen ausgewiesen werden.[69] Ein Modell, das in wenigen Jahren zu den wertvollsten

Gegenständen eines Unternehmens gehören kann, wäre in dessen Bilanz unsichtbar und erschiene erst beim Verkauf, als Teil des Kaufpreises. Wie ein solcher Gegenstand zu bewerten, zu übertragen und zu besteuern ist, wird Gerichte, Prüfer und Gesetzgeber beschäftigen. Das Paper stellt diese Fragen und gibt sie als Arbeitsauftrag an die Fachleute weiter.

Die dritte Spielart berührt außerdem eine Frage, die größer ist als dieses Paper und gesellschaftlich von Jahr zu Jahr dringlicher wird. Wenn Agenten einen wachsenden Teil der Arbeit übernehmen, was geschieht mit den Menschen, deren Wert in dem liegt, was sie wissen? Ein Unternehmens-LHNM gibt eine Antwort für einen Teil von ihnen: Wer ein Leben lang gelernt hat, wer die Kunden, die Lieferanten, die Fehler und die Auswege kennt, wird nicht ersetzt, sondern beteiligt. Sein Wissen wird zu einem Anteil an einem Vermögen, das das Unternehmen ohne ihn nicht hätte, und er behält den Anreiz, es aktuell zu halten, statt es beim Ausscheiden mitzunehmen. Das löst nicht die Frage, was aus den vielen wird, deren Arbeit sich beschreiben und darum automatisieren lässt. Es zeigt aber, dass es Wissen gibt, das die Automatisierung nicht abwertet, sondern erst sichtbar macht.

Warum die Unternehmens-KI bisher so wenig bewirkt

Die dritte Spielart beantwortet nebenbei eine Frage, die die Unternehmens-KI seit zwei Jahren begleitet. Die Nutzung ist breit: In Deutschland setzen 2026 beispielsweise erstmals mehr als die Hälfte der Unternehmen ab zwanzig Beschäftigten KI ein,[70, 71] im Mittelstand war es zuletzt (Daten 2022 bis 2024) ein Fünftel.[72] Nach eigener Auskunft schöpfen 3 Prozent der Anwender das Potenzial stark aus, 59 Prozent gar nicht, und jedes dritte Unternehmen setzt KI vor allem aus Sorge ein, den Anschluss zu verlieren.[70] Die Wirkung ist flach: Weltweit skalieren 44 Prozent der Unternehmen KI über das Haus hinweg, aber nur 37 Prozent sehen überhaupt eine Ergebniswirkung, und dieser Anteil hat sich seit 2025 nicht bewegt.[73] Gartner erwartet, dass über 40 Prozent der Agentenprojekte bis Ende 2027 abgebrochen werden, wegen Kosten, unklarem Nutzen oder unzureichender Risikokontrollen.[74] Eine Auswertung von mehr als 12.000 europäischen Unternehmen durch Ökonomen der Europäischen Investitionsbank und der Bank für Internationalen Zahlungsausgleich beziffert den Produktivitätsgewinn durch KI auf rund 4 Prozent, einen einmaligen Niveaueffekt, der bei mittleren und großen Unternehmen deutlich größer ausfällt als bei kleinen und mit jedem Prozentpunkt zusätzlicher Ausgaben für Schulung stärker wächst als mit Ausgaben für Software.[75] Die übliche Erklärung lautet Datenqualität, Fähigkeiten, Kultur; BCG beziffert, dass die erfolgreichen Häuser 70 Prozent ihres Aufwands in Menschen und Prozesse stecken und nur 10 Prozent in Algorithmen.[76] Die Ökonomie kennt das Muster als Produktivitätsparadox: Robert Solow bemerkte 1987, man sehe das Computerzeitalter überall außer in den Produktivitätsstatistiken,[77] und Brynjolfsson, Rock und Syverson haben gezeigt, dass Basistechnologien eine J-Kurve durchlaufen, weil die unsichtbaren Investitionen in Abläufe und Fähigkeiten der messbaren Wirkung um Jahre vorausgehen.[78] In der Community des Autors ist ein Befund in diesem Herbst häufig zu hören: Die Unternehmen hätten Schwierigkeiten, die Fähigkeiten der Modelle in ihre Abläufe zu bringen, und die Adaption bleibe weit hinter dem zurück, was allgemein erwartet und suggeriert werde; von Familien und Family Offices ist in dieser Debatte so gut wie nie die Rede. Dieses Paper benennt, was in dieser J-Kurve fehlt: Ein Agent, der die Dokumente des Hauses kennt, aber nicht sein Urteil, produziert generische Arbeit. Er kann den Lieferantenvertrag zusammenfassen und weiß nicht, dass dieser Lieferant beim letzten Engpass als Einziger geliefert hat. Die Modelle entfalten ihre Wirkung

erst, wenn sie an die menschliche Schicht angeschlossen sind, und diese Schicht ist bisher kaum irgendwo gebaut.

10 · Gegenthese

Die bisherigen Abschnitte beruhen auf Praxiserfahrung und Thesen. Dieser Abschnitt nimmt die Gegenseite ein und legt ihre Argumente offen. Es sind insgesamt sechs.

Erstens: Es ist keine Kategorie, sondern eine Kombination. Delphi plus Boardy plus Affinity ergibt ein LHNM; die Teile gibt es, nur die Verbindung ist neu. Das ist richtig, und es gilt für die meisten Kategorien der Technikgeschichte. Ein Smartphone war ein Telefon plus ein Rechner plus eine Kamera. Die Frage ist nicht, ob die Teile existieren, sondern ob die Verbindung etwas kann, was keines der Teile kann. Ein Klon kann niemanden anrufen, ein Vermittlungsdienst hat kein Urteil, eine Relationship-Intelligence-Software kein Netz von außen. Das LHNM vereint alle drei, und erst dadurch beantwortet es die Frage, mit der dieses Paper beginnt.

Zweitens: Große Häuser bauen das intern in Wochen. Jede Bank, jede Kanzlei, jeder Konzern hat die Daten und das Geld. Auch das ist richtig, und keines dieser Häuser wird das Ergebnis je nach außen anbieten, weil die Beziehungen ihr Geschäft sind. Das LHNM ist in dem Sinn das erste Modell dieser Art, das man von außen befragen kann. Der Vorsprung liegt nicht in der Technik, sondern im Geschäftsmodell und in der Bereitschaft, es zu betreiben.

Drittens: Der Experte bleibt der Engpass. Das Urteil und die Tür hängen an einer oder wenigen zentralen Personen, und die skalieren nicht. Das ist die ernsteste Schwäche, und sie lässt sich nur messen, nicht wegdiskutieren. Die relevante Kennzahl ist der Anteil einer Anfrage, den die Maschine ohne den Experten erledigt, und die Zahl der Anfragen, die er pro Woche beurteilen kann, wenn die Vorarbeit entfällt. Beides wird im beschriebenen Fall an den ersten Fällen gemessen. Der Autor erwartet eine Steigerung der Produktivität um ein Vielfaches, in Verbindungen, in Zeit und in Geld; belegt ist sie noch nicht. Hinzu kommt, dass ein Experte autorisieren kann, wer in seinem Namen Türen öffnet; ein LHNM ist auch das Werkzeug, mit dem er das zum ersten Mal verantworten kann. Für Produktivität und Skalierung heißt das: Die Vorarbeit skaliert mit der Maschine, das Urteil skaliert mit der Zahl der Menschen, denen der Experte vertraut. Ein Haus, das drei solcher Menschen hat, kann ein Vielfaches dessen bewegen, was heute ein Berater mit zehn Mitarbeitern schafft; eines, das nur eine Person hat, gewinnt Zeit, aber keine zweite Tür.

Viertens: Beziehungswissen verfällt. Was 2015 galt, gilt 2026 nicht mehr; Menschen wechseln, Häuser verschwinden. Richtig, und genau deshalb hat jeder Eintrag ein Datum, und genau deshalb lernt das Modell aus seinem Gebrauch. Ein Netz, das nicht benutzt wird, verfällt. Ein Netz, das täglich befragt und bestätigt wird, altert langsamer als sein Eigentümer. Die Expertensysteme sind nicht nur an der Beschaffung gescheitert, sondern an der Pflege; ein LHNM, das einmal befüllt und dann sich selbst überlassen wird, würde denselben Weg gehen. Deshalb ist die Rückkopplung aus Abschnitt 7 keine Zugabe, sondern die Bedingung, unter der das Modell lebt.

Fünftens: Diskretion. Nutzer geben Zugang, weil sie Diskretion erwarten, und ein LHNM muss diese Erwartung in jedem Schritt erfüllen. Wie das gelingt, steht in Abschnitt 5: Ein LHNM, das Daten herausgibt, ist keines. Nur eine Architektur, die nichts herausgibt und keine Listen erzeugt, verdient das Vertrauen, von dem sie lebt. Dazu kommt ein zweites Element, das in der Debatte oft fehlt: der Nutzen, der die

Zustimmung einschließt. Der Zulieferer, den ein Musikproduzent fragt, ob er eine Tournee ausstatten kann, hat dieser Anfrage nie ausdrücklich zugestimmt, und er wird sie trotzdem immer wollen. Der Kollege, dem ein Chirurg einen Patienten überweist, den er selbst nicht operieren sollte, ebenso. Ein LHNM, das weiß, dass die Wahrscheinlichkeit hoch ist, dass die Gegenseite sich über die Anfrage, das Angebot oder den Hinweis freut und dass ihr die Information im Zweifel Geld wert wäre, fragt nicht gegen ihr Interesse, sondern in ihrem. Ob das reicht, entscheiden am Ende die Beteiligten, nicht der Autor.

Sechstens: Das Wissen wird ohnehin geerntet. Eine Industrie bezahlt Fachleute dafür, ihr Urteil in die großen Modelle einzuspeisen, und in wenigen Jahren wird das Grundmodell wissen, was heute nur der Experte weiß. Für das Fachwissen trifft das teilweise zu, und das Paper widerspricht dem nicht. Es trifft aber nicht zu für das, was ein LHNM im Kern enthält: wer in einer bestimmten Welt was besitzt, will und entscheidet, wem man vertrauen kann und wer die Tür öffnet. Dieses Wissen lässt sich nicht als Trainingsdatensatz verkaufen, weil es nicht generisch ist und weil es mit der Beziehung verbunden bleibt, aus der es stammt. Was ein Grundmodell lernen kann, verliert ein LHNM. Was es nicht lernen kann, bleibt.

11 · Grenzen und testbare Hypothesen

Dieses Paper beschreibt ein System im internen Betrieb, vor der Öffnung nach außen; seine Funktion und Wirkung konnte der Autor dort bereits prüfen. Es ist ein wachsendes System, und der Aufwand an Daten und Wissen, der darin steckt, sollte nicht unterschätzt werden; viele Organisationen bringen Wissen aus Jahrzehnten mit, das erst gehoben werden muss. Da das System in den unteren beiden Schichten des Eisbergs arbeitet, bleiben die Einzelheiten unveröffentlicht. Was sich sagen lässt: Es stellt bereits heute Zusammenhänge, Türen und Informationen her, die der Autor in zwanzig Jahren Praxis so nicht hatte. Die Grenzen des Papers sind damit benannt: Es stützt sich auf einen einzigen Fall, den des Autors, und auf eine Prior-Art-Recherche, die Abwesenheit nie beweisen kann; interne Systeme von Banken und Family Offices sind nicht öffentlich. Die Größenangaben zum Korpus sind Größenordnungen, keine Messwerte, weil der Bestand wächst. Die Wirkung auf Nutzerseite ist an Einzelfällen gezeigt, nicht an einer Serie.

Daraus folgen fünf Hypothesen, die sich überprüfen lassen. Erstens: Ein LHNM findet in mindestens neun von zehn Fällen dieselben Gegenüber, die der Experte ohne Maschine gefunden hätte, und in einem messbaren Anteil zusätzliche, die er übersehen hätte. Zweitens: Der Anteil einer Anfrage, den die Maschine ohne den Experten erledigt, liegt nach dem Aufbau über 80 Prozent, und die Vorarbeit entspricht der Arbeit von 20 bis 30 Festangestellten eines klassischen Beratungshauses (Abschnitt 6); gemessen an der Wertschöpfungskette aus Suchen, Prüfen, Ansprechen und Nachfassen, die heute Wochen an Arbeitszeit bindet, wäre das ein Sprung um eine Größenordnung. Drittens: Die Zeit von Anliegen bis Vorstellung, Lösung, Absage sinkt von Wochen auf Tage oder gar Stunden. Viertens: Mindestens eine zweite Domäne (Film, Musik, Medizin, Verwaltung) lässt sich mit derselben Architektur ohne Änderung der Schichten abbilden; das ist auch für Häuser entscheidend, die in mehreren Branchen zugleich tätig sind, und für Behörden und Ministerien, die über Ressortgrenzen hinweg arbeiten müssen. Fünftens: Nutzer zahlen für Ergebnisse Preise, die um Größenordnungen über denen für Daten liegen, was, wie in Abschnitt 9 beschrieben, eine neue Preisbildung verlangt, sollten sich LHNMs durchsetzen. Jede dieser Hypothesen kann scheitern. Das Paper ist eine

testbare Hypothese, keine bewiesene Überlegenheit, und es lädt ausdrücklich zu Kritik und Weiterentwicklung ein.

Annex

Glossar

Large Language Model (LLM): ein auf Text trainiertes neuronales Netz, das Sprache vorhersagt und daraus Wissen und Schlussfolgerungen ableitet. *World Model*: ein Modell, das das Verhalten einer physischen Umgebung lernt, um darin handeln oder planen zu können. *Vertical AI*: Anwendungen großer Modelle auf eine Branche mit deren Daten und Abläufen. *Retrieval*: das Heraussuchen passender Ausschnitte aus einer Wissensbasis, bevor ein Sprachmodell antwortet. *Skill*: ein ausführbares Regelwerk, das einem Sprachmodell ein Verfahren vorgibt. *Konnektor*: eine Schnittstelle zu einer externen Datenquelle. *Datennetzwerkeffekt*: der Effekt, dass ein System mit jedem Nutzer für den nächsten besser wird.

Fußnoten

1 · Michael Polanyi, The Tacit Dimension, Doubleday, Garden City (NY) 1966; Neuauflage University of Chicago Press, Chicago 2009. Zitat S. 4: „we can know more than we can tell“.

2 · Peter Thiel mit Blake Masters, Zero to One: Notes on Startups, or How to Build the Future, Crown Business, New York 2014.

3 · Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, Illia Polosukhin, „Attention Is All You Need“, Advances in Neural Information Processing Systems 30 (NeurIPS 2017), S. 5998 bis 6008.

4 · Tom B. Brown et al., „Language Models are Few-Shot Learners“, Advances in Neural Information Processing Systems 33 (NeurIPS 2020), S. 1877 bis 1901.

5 · David Ha, Jürgen Schmidhuber, „World Models“, arXiv:1803.10122, 27. März 2018, https://arxiv.org/abs/1803.10122

6 · Yann LeCun, „A Path Towards Autonomous Machine Intelligence“, Version 0.9.2, 27. Juni 2022, OpenReview, https://openreview.net/pdf?id=BZ5a1r-kVsf

7 · NVIDIA, „NVIDIA Launches Cosmos World Foundation Model Platform to Accelerate Physical AI Development“, Pressemitteilung, 6. Januar 2025, https://investor.nvidia.com/news/press-release-details/2025/NVIDIA-Launches-Cosmos-World-Foundation-Model-Platform-to-Accelerate-Physical-AI-Development/default.aspx

8 · SDxCentral, „AMD acquires AI research firm World Labs in all-stock deal worth $8.2B“, 29. September 2026, https://www.sdxcentral.com/news/amd-acquires-ai-research-firm-world-labs-in-all-stock-deal-worth-82b/ (Vereinbarung angekündigt am 28. September 2026; Abschluss vorbehaltlich behördlicher Genehmigungen bis Ende 2026 erwartet).

9 · Robotics & Automation News, „AgiBot claims top spot in global humanoid robot shipments in 2025 with more than 5,100 units delivered“ (Omdia-Zahlen), 21. Januar 2026, https://roboticsandautomationnews.com/2026/01/21/agibot-claims-top-spot-in-global-humanoid-robot-shipments-in-2025-with-more-than-5100-units-delivered/98223/

10 · Fortune, „Tesla is hiring workers for $48 an hour to wear motion-capture suits to train its humanoid robots“, 19. August 2024, https://www.fortune.com/2024/08/19/tesla-robot-hiring-workers-optimus-training-ai

11 · Michelle Kim, „The gig workers who are training humanoid robots at home“, MIT Technology Review, 1. April 2026 (Leserwahl zum „11. Durchbruch“ der Liste 10 Breakthrough Technologies 2026), https://www.technologyreview.com/2026/04/01/1134863/humanoid-data-training-gig-economy-2026-breakthrough-technology/

12 · Google DeepMind, „Scaling up learning across many different robot types“ (Open X-Embodiment), 3. Oktober 2023, https://deepmind.google/discover/blog/scaling-up-learning-across-many-different-robot-types/

13 · Rodney Brooks, „Why Today's Humanoids Won't Learn Dexterity“, 26. September 2025, https://rodneybrooks.com/why-todays-humanoids-wont-learn-dexterity/

14 · Business Today, „OpenAI introduces Dots: always-on AI agents that work 24/7 and act on your behalf“, 30. September 2026, https://www.businesstoday.in/technology/artificial-intelligence/story/openai-introduces-dots-always-on-ai-agents-that-work-247-and-act-on-your-behalf-558688-2026-09-30

15 · Techeconomy, „Meta AI Grows Hands: Muse Spark 1.1 Turns Chatbot into an Agent That Plans, Books and Follows Through“, 28. Juli 2026, https://techeconomy.ng/meta-ai-grows-hands-muse-spark-1-1-turns-chatbot-into-an-agent

16 · Google DeepMind, „AlphaEvolve: A Gemini-powered coding agent for designing advanced algorithms“, 14. Mai 2025, https://deepmind.google/blog/alphaevolve-a-gemini-powered-coding-agent-for-designing-advanced-algorithms/

17 · Dario Amodei, „We Must Pace the Frontier“, September 2026, https://darioamodei.com/post/we-must-pace-the-frontier

18 · Mark E. J. Newman, Networks: An Introduction, Oxford University Press, Oxford 2010, insbesondere Kapitel 6 und 7 (gewichtete und gerichtete Graphen, Zentralitätsmaße).

19 · Sergey Brin, Lawrence Page, „The Anatomy of a Large-Scale Hypertextual Web Search Engine“, Computer Networks and ISDN Systems 30 (1998), S. 107 bis 117.

20 · Peter McCullagh, „What is a statistical model?“, The Annals of Statistics 30 (2002), Nr. 5, S. 1225 bis 1310. Ein statistisches Modell ist dort eine Menge parametrisierter Wahrscheinlichkeitsverteilungen über die Daten; ob die Parameter geschätzt oder gesetzt werden, ist für die Definition unerheblich.

21 · microagi, „microagi to build future of AI robotics on Google Cloud“, Pressemitteilung (PR Newswire), 22. Juli 2026, https://www.prnewswire.com/news-releases/microagi-to-build-future-of-ai-robotics-on-google-cloud-302830752.html (Unternehmensangabe).

22 · SiliconANGLE, „Microagi nabs $55M to teach factory robots how to work“, 16. Juli 2026, https://siliconangle.com/2026/07/16/microagi-nabs-55m-teach-factory-robots-work/ ; Sifted, „Munich robotics startup microagi raises $55m in Germany's largest ever seed round“, Juli 2026, https://sifted.eu/articles/munich-robotics-startup-microagi-raises-55m-germanys-largest-ever-seed-round

23 · Bessemer Venture Partners, „Part I: The future of AI is vertical“, 3. September 2024, https://www.bvp.com/atlas/part-i-the-future-of-ai-is-vertical

24 · Harvey, „Harvey raises $550M at a $15.5B valuation to help legal teams own their intelligence“, 9. September 2026, https://www.harvey.ai/blog/harvey-raises-dollar550m-at-a-dollar155b-valuation-to-help-legal-teams-own-their-intelligence

25 · Axios Pro, „Abridge raises $300M at $5.3B valuation“, 24. Juni 2025, https://www.axios.com/pro/health-tech-deals/2025/06/24/abridge-raise-300m-5b-valuation-billing-scribe

26 · Bloomberg News, „The Hottest AI Companies Right Now Are ‚Apps‘“, 6. März 2025, https://www.bloomberg.com/news/articles/2025-03-06/the-hottest-ai-companies-right-now-are-apps

27 · Bessemer Venture Partners, „Part IV: Ten principles for building strong vertical AI businesses“, 28. Januar 2025, https://www.bvp.com/atlas/part-iv-ten-principles-for-building-strong-vertical-ai-businesses („models will cease to be a moat“).

28 · Marc Andrusko, Alex Rampell (a16z), „Fruits of the Walled Garden“, 9. Oktober 2025, https://a16z.com/fruits-of-the-walled-garden/ („the painstakingly assembled dataset that no one else has“).

29 · Affinity, „Warm Intro Agent“, Hilfeseite, abgerufen am 24. Oktober 2026, https://support.affinity.co/s/article/Warm-Intro-Agent

30 · Louisa AI, „Investment Banking“, Produktseite, abgerufen am 24. Oktober 2026, https://louisa.ai/investment-banking/

31 · Pearl, „Real-Time Expert Matching: How Pearl's Intelligent Routing Delivers Fast, Accurate Answers“, 18. Juli 2025, https://www.pearl.com/post/real-time-expert-matching-how-pearl-s-intelligent-routing-delivers-fast-accurate-answers

32 · Fast Company, „Meet Delphi, the AI startup that lets experts turn themselves into chatbots“, 24. Juni 2025, https://www.fastcompany.com/91356476/delphi-ai-digital-mind

33 · Creandum, „Backing Boardy“, https://creandum.com/commitments/boardy (Seed-Runde über 8 Millionen US-Dollar unter Führung von Creandum, angekündigt am 14. Januar 2025).

34 · FinTech Global, „AYU launches AI capital matching for family offices“, 23. Februar 2026, https://fintech.global/2026/02/23/ayu-launches-ai-capital-matching-for-family-offices/

35 · AYU Capital, „Submit your deck“, Produktseite, abgerufen am 30. Oktober 2026, https://cupid.thisisayu.com/ („Powered by Cupid, our proprietary AI capital concierge“).

36 · Y Combinator, „PartnerHQ: Buy warm intros to your prospects“, Launch-Seite, 14. März 2024, https://www.ycombinator.com/launches/Kee-partnerhq-buy-warm-intros-to-your-prospects

37 · Edward A. Feigenbaum, „The Art of Artificial Intelligence: Themes and Case Studies of Knowledge Engineering“, Proceedings of the 5th International Joint Conference on Artificial Intelligence (IJCAI 1977), S. 1014 bis 1029; Volltext als Stanford-Report STAN-CS-77-621, https://apps.dtic.mil/sti/tr/pdf/ADA046289.pdf

38 · Elliot Soloway, Judy Bachant, Keith Jensen, „Assessing the Maintainability of XCON-in-RIME: Coping with the Problems of a VERY Large Rule-Base“, Proceedings of AAAI-87, S. 824 bis 829.

39 · Ikujiro Nonaka, Hirotaka Takeuchi, The Knowledge-Creating Company: How Japanese Companies Create the Dynamics of Innovation, Oxford University Press, New York 1995.

40 · Dealroom, „Mercor doubles to $2B gross revenue run rate as AI labs buy expert data“, 6. Juli 2026, https://dealroom.co/news/137121-mercor-doubles-to-2b-gross-revenue-run-rate-as-ai-labs-buy-expert-data/ ; TechCrunch, „Mercor quintuples valuation to $10B with $350M Series C“, 27. Oktober 2025, https://techcrunch.com/2025/10/27/mercor-quintuples-valuation-to-10b-with-350m-series-c/

41 · The Decoder (nach Bloomberg), „OpenAI trains AI to take on junior banking tasks“, 21. Oktober 2025, https://the-decoder.com/bloomberg-openai-trains-ai-to-take-on-junior-banking-tasks/

42 · Harvey, „Introducing Workflow Builder“, 24. Juni 2025, https://www.harvey.ai/blog/introducing-workflow-builder

43 · Kowatek, „MasterClass On Call gives you on-demand access to AI facsimiles of its experts“, 11. Dezember 2024, https://blog.kowatek.com/2024/12/11/masterclass-on-call-gives-you-on-demand-access-to-ai-facsimiles-of-its-experts/

44 · Gianlucca Zuin, Saulo Mastelini, Túlio Loures, Adriano Veloso, „Leveraging Large Language Models for Tacit Knowledge Discovery in Organizational Contexts“, arXiv:2507.03811, 4. Juli 2025, https://arxiv.org/abs/2507.03811 (820 von 864 Simulationsläufen mit vollständiger Rekonstruktion; synthetische Organisation, keine reale Belegschaft).

45 · Mina Cho, Russell Funk, Alok Gupta, Mochen Yang, „Large Language Models Explain Experts Better Than Experts Themselves“, Carlson School of Management, University of Minnesota, Entwurf Juni 2026, arXiv:2608.07488, https://arxiv.org/abs/2608.07488

46 · Akimoto Yusuke, Yamazaki Seiya (ARISE analytics), „Large Network Model: 大規模言語モデルを応用した通信ネットワークシミュレーションのための生成モデルの検討“, 39. Jahrestagung der Japanese Society for Artificial Intelligence (JSAI 2025), Beitrag 2Win5-96, https://doi.org/10.11517/pjsai.JSAI2025.0_2Win596

47 · Srinivas Kilambi, Mahesh Banavar, Large Numerical Models from a Business Perspective: LNM, a Parallel Universe to LLM, Springer, Cham 2026, Kapitel 3, https://link.springer.com/chapter/10.1007/978-3-032-14869-8_3

48 · Inavate APAC, „Refik Anadol announces first open-source generative AI model based on nature“, 15. Januar 2024, https://www.inavateapac.com/news/article/refik-anadol-announces-first-opensource-generative-ai-model-based-on-nature

49 · Shomila Malik, „Large Relationship Models: The AI That's Been Hiding in Plain Sight“, Medium, 17. Juni 2025, https://shomila.medium.com/large-relationship-models-the-ai-thats-been-hiding-in-plain-sight-d9277d266627

50 · Altrata, World Ultra Wealth Report 2025, 30. September 2025, https://altrata.com/reports/world-ultra-wealth-report-2025 (510.810 Personen mit einem Nettovermögen über 30 Millionen US-Dollar).

51 · Mark S. Granovetter, „The Strength of Weak Ties“, American Journal of Sociology 78 (1973), Nr. 6, S. 1360 bis 1380.

52 · Ronald S. Burt, Structural Holes: The Social Structure of Competition, Harvard University Press, Cambridge (MA) 1992.

53 · Toby Stuart, Anointed: The Extraordinary Effects of Social Status in a Winner-Take-Most World, Simon & Schuster, New York 2025.

54 · hiQ Labs, Inc. v. LinkedIn Corp., 31 F.4th 1180 (9th Cir. 2022); nach der Rückverweisung Urteil des U.S. District Court for the Northern District of California vom 4. November 2022 überwiegend zugunsten von LinkedIn; der Rechtsstreit endete im Dezember 2022 mit einem Vergleich. LinkedIn geht seit Jahren gerichtlich gegen das automatisierte Auslesen seiner Profile vor und beschränkt den Zugriff über Schnittstellen auf wenige Partner.

55 · Verordnung (EU) 2016/679 (Datenschutz-Grundverordnung), insbesondere Artikel 6 Absatz 1 Buchstabe f, Artikel 9, Artikel 14 und Artikel 15.

56 · Verordnung (EU) 2024/1689 des Europäischen Parlaments und des Rates vom 13. Juni 2024 (KI-Verordnung), ABl. L vom 12. Juli 2024, insbesondere Artikel 6 Absatz 1 und Anhang I.

57 · STIHL, „Production and Sales“, Unternehmensseite, abgerufen am 30. Oktober 2026, https://corporate.stihl.com/en/about-stihl/production-sales („available in more than 160 countries across five continents“).

58 · Martin-W. Buchenau, „Stihl-Chef: Neue Fertigung in Deutschland? ‚Da fehlt mir derzeit die Fantasie‘“, Interview mit Michael Traub, Handelsblatt, 25. Oktober 2026. Zitate: „Stihl hat als Familienunternehmen nicht ständig den Kapitalmarkt im Nacken“; „Nicht die Technologie bestimmt, sondern der Kunde“; zum Fachhandel: „Da sind wir fast religiös“; zum ausgetauschten US-Chef: „Er wollte ein anderes Spiel spielen als wir.“

59 · Der Begriff „Brain Trust“ wurde 1932 für den Beraterkreis des Präsidentschaftskandidaten Franklin D. Roosevelt geprägt, nach Darstellung Raymond Moleys von James M. Kieran, Reporter der New York Times; Samuel Rosenman schrieb ihn Louis Howe zu (Raymond Moley, Rexford Tugwell, Adolf Berle, alle Columbia University). Vgl. Raymond Moley, After Seven Years, Harper & Brothers, New York 1939.

60 · David A. Pieper, Old Money, New Machines (Arbeitstitel), White Paper in Vorbereitung, 2026; dort Kapitel 1.4 (die zwei Hälften des Family Office), 5.2 (Legacy, Familienverfassung) und 6 (das Family Office als Steuerungszentrale).

61 · Yan Tao, Olga Viberg, Ryan S. Baker, René F. Kizilcec, „Cultural bias and cultural alignment of large language models“, PNAS Nexus 3 (2024), Nr. 9, pgae346. Die Antworten der untersuchten Modelle lagen auf den Werteskalen des World Values Survey am nächsten bei englischsprachigen und protestantisch-europäischen Ländern.

62 · Teikoku Databank, „全国「老舗企業」分析調査（2025年）“ (Analyse der Traditionsunternehmen 2025), 27. März 2026: 46.708 Unternehmen mit mehr als hundert Jahren Geschichte, Stand Dezember 2025; Mitteilung wiedergegeben unter https://www.zaikei.co.jp/releases/3365307/

63 · KfW Research, „Standort Zukunft: Wie Deutschland zu neuer Stärke und Wachstum findet“, Kapitel 3.4 Nachfolge, 2026, https://www.kfw.de/PDF/Download-Center/Konzernthemen/Research/PDF-Standort-Zukunft/3.4-Nachfolge.pdf

64 · DIHK, „Industrie investiert stärker im Ausland: Kostendruck erreicht historischen Höchststand“, Sonderauswertung der DIHK-Konjunkturumfrage Jahresbeginn 2026 (rund 1.700 Industrieunternehmen), 16. April 2026, https://www.dihk.de/de/newsroom/industrie-investiert-staerker-im-ausland-kostendruck-erreicht-historischen-hoechststand-176268 („In diesem Jahr planen 43 Prozent der Industriebetriebe Investitionen außerhalb von Deutschland“; 41 Prozent nennen Kostenersparnis als Motiv, der höchste Wert seit 2003).

65 · IG Metall, „Einigung bei Miele: Standorte bis 2028 sicher“, 10. Juni 2024, https://www.igmetall.de/im-betrieb/einigung-bei-miele-standorte-bis-2028-sicher (Verlagerung der Waschmaschinenproduktion von Gütersloh nach Polen, 700 betroffene Arbeitsplätze in Gütersloh, 1.300 in Deutschland insgesamt).

66 · Interfax, „Ukrainian State Border Guard Service provides border-crossing statistics“ (mit UNHCR-Daten, Stand 19. Februar 2026: 5,924 Millionen), 20. April 2026, https://interfax.com/newsroom/top-stories/117217/

67 · TRUMPF, „Minister-President Winfried Kretschmann visits TRUMPF: regional innovation set to power future industrial growth“, Pressemitteilung, Ditzingen, 19. Januar 2022, https://www.trumpf.com/pl_PL/newsroom/globalne-informacje-prasowe/komunikaty-prasowe/release/minister-president-winfried-kretschmann-visits-trumpf-regional-innovation-set-to-power-future-industrial-growth/ („ASML uses EUV lasers from TRUMPF to manufacture lithography systems“); Eigentümerstruktur (Familie Leibinger) nach Wikipedia, „Trumpf“, https://en.wikipedia.org/wiki/Trumpf (Sekundärquelle).

68 · Yashvardhan Sharma, „Test and Assembly“, Kapitel 13 in: Chip Supply Chain: How AI Chips Are Made, chipsupplychain.org, Ausgabe vom 21. Oktober 2026, https://chipsupplychain.org/pdf/test-and-assembly.pdf (nach CSET-Auswertung von TechInsights-Daten für 2025: Advantest 62,7 Prozent des Markts für Chiptester, DISCO 87 Prozent des Markts für Dicing- und Grinding-Anlagen).

69 · International Accounting Standard 38, Intangible Assets, Paragraph 63: „Internally generated brands, mastheads, publishing titles, customer lists and items similar in substance shall not be recognised as intangible assets.“

70 · Bitkom, „Erstmals nutzt Mehrheit der Unternehmen KI“, Presseinformation, 14. September 2026 (603 Unternehmen ab 20 Beschäftigten; 57 Prozent Nutzung nach 36 Prozent 2025 und 20 Prozent 2024; 3 Prozent „eher stark“, 28 Prozent „eher wenig“, 59 Prozent „gar nicht“ ausgeschöpft; 33 Prozent aus Sorge, den Anschluss zu verlieren), https://www.bitkom.org/Presse/Presseinformation/Erstmals-nutzt-Mehrheit-Unternehmen-KI

71 · ifo Institut, „Mehr als die Hälfte der Unternehmen nutzt Künstliche Intelligenz“, 5. Juni 2026 (54,5 Prozent, alle Unternehmensgrößen), https://www.ifo.de/fakten/2026-06-05/mehr-als-die-haelfte-der-unternehmen-nutzt-kuenstliche-intelligenz

72 · KfW Research, „Künstliche Intelligenz im Mittelstand: einfach zu handhabende Technologien mit breiten Einsatzgebieten überwiegen“, Fokus Volkswirtschaft Nr. 554, 29. Juli 2026 (KfW-Mittelstandspanel, Nutzung 2022 bis 2024, erhoben Frühjahr 2025),

https://www.kfw.de/PDF/Download-Center/Konzernthemen/Research/PDF-Dokumente-Fokus-Volkswirtschaft/Fokus-2026/Fokus-Nr.-554-Juli-2026-KI_Mittelstand.pdf

73 · McKinsey & Company, „The State of AI in 2026: On the road to ROI“, August 2026 (1.719 Befragte in 97 Ländern), https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai

74 · Gartner, „Gartner Predicts Over 40% of Agentic AI Projects Will Be Canceled by End of 2027“, Pressemitteilung, 25. Juni 2025, https://www.gartner.com/en/newsroom/press-releases/2025-06-25-gartner-predicts-over-40-percent-of-agentic-ai-projects-will-be-canceled-by-end-of-2027

75 · Iñaki Aldasoro, Leonardo Gambacorta, Rozália Pál, Debora Revoltella, Christoph Weiss, Marcin Wolski, „AI adoption, productivity and employment: evidence from European firms“, BIS Working Paper Nr. 1325 und CEPR Discussion Paper Nr. 21082, 2026, https://www.bis.org/publ/work1325.pdf (EIB Investment Survey 2019 bis 2024, über 12.000 Unternehmen; Zusammenfassung: VoxEU, „How AI is affecting productivity and jobs in Europe“, https://cepr.org/voxeu/columns/how-ai-affecting-productivity-and-jobs-europe).

76 · Boston Consulting Group, „From Potential to Profit: Closing the AI Impact Gap“, 15. Januar 2025 (über 1.800 Führungskräfte), https://www.bcg.com/publications/2025/closing-the-ai-impact-gap

77 · Robert M. Solow, „We’d Better Watch Out“, Rezension in: The New York Times Book Review, 12. Juli 1987, S. 36 („You can see the computer age everywhere but in the productivity statistics“).

78 · Erik Brynjolfsson, Daniel Rock, Chad Syverson, „The Productivity J-Curve: How Intangibles Complement General Purpose Technologies“, American Economic Journal: Macroeconomics 13 (2021), Nr. 1, S. 333 bis 372.

Hinweis zur Arbeitsweise

Alle Gedanken, Thesen und Einschätzungen in diesem White Paper sind die des Autors und über zwei Jahrzehnte Praxis gewachsen. Künstliche Intelligenz (Claude, Gemini) wurde beim Prüfen der Vorveröffentlichungslage, beim Referenzieren, beim Recherchieren von Quellen, für Form und Rechtschreibung und für Textentwürfe unter redaktioneller Kontrolle des Autors eingesetzt. Das Paper beschreibt ein System, das selbst auf dieser Zusammenarbeit beruht; der Autor hält es für angemessen, das offen zu sagen. Die KI hat das Paper inhaltlich nicht geschrieben.

Über den Autor

David A. Pieper ist Investor, Unternehmer und seit über zwanzig Jahren in der Welt großer Familienvermögen tätig, an der Schnittstelle von Family Offices, Familienunternehmen, Kapitalmarkt und Immobilientransaktionen. Er hält einen Executive MBA (IREBS) und einen LL.M. in Private Wealth Management, hat zu Stiftungen und Nachfolge publiziert und ist Autor der White-Paper-Reihe zu Momentum, Tail Risk und Quality Investing. Er baut derzeit das in diesem Paper beschriebene Large Human Network Model für die Welt der Familien, Family Offices und Stiftungen.