

KI für Entwickler

Was dahinter steckt: vom Sprachmodell bis zum Agenten, für PowerBuilder-Entwickler

Was passiert hier eigentlich?

Eingabe

„Schreib mir eine Funktion, die eine DataWindow-Zeile prüft ...“



Ausgabe

Code, Erklärungen, Antworten – oft verblüffend gut, manchmal falsch

Leitsatz des Vortrags

Wir wissen genau, wie man ein LLM baut und trainiert – aber nur begrenzt, warum es im Einzelnen tut, was es tut.

Einordnung: KI, ML, Deep Learning, LLM

Künstliche Intelligenz

Machine Learning

Deep Learning

LLM

Sprachmodelle wie Claude

Künstliche Intelligenz

Oberbegriff: Maschinen lösen Aufgaben, die Intelligenz erfordern, vom Schachprogramm bis zum Spamfilter.

Machine Learning

Das System lernt Muster aus Beispielen, statt dass jemand Regeln programmiert.

Deep Learning

Machine Learning mit vielen Schichten künstlicher Neuronen.

LLM

Ein solches Netz, trainiert darauf, Text fortzusetzen. Thema des Rests dieses Vortrags.

Lernen aus Beispielen statt Regeln

● Klassisch programmiert



Beispiel: Rechnungsprüfung als WENN-DANN-Regeln, die jemand schreibt und pflegt.

● Machine Learning



Beispiel: aus 10.000 geprüften Rechnungen lernt das Modell selbst, was auffällig ist.

WARUM DAS WICHTIG IST

Ein LLM ist kein Programm mit Regeln, sondern Milliarden gelernter Zahlen. Deshalb lässt es sich nicht einfach debuggen, und deshalb braucht man Prüfungen.

Fahrplan für die nächste Stunde

1 Einstieg und Einordnung
Minute 0–8

2 Exkurs: Wie ein LLM funktioniert
Minute 8–28

3 Vom Modell zum Werkzeug
Minute 28–50

4 Grenzen und Risiken
Minute 50–58

5 Fragen
Minute 58–60

TEIL 2
Lokale LLMs für PowerBuilder

Roter Faden: Wir wissen genau, wie man ein LLM baut, aber nur begrenzt, warum es im Einzelnen tut, was es tut. Deshalb braucht es Kontext und Prüfung.


Ein LLM sagt das nächste Token vorher

„Der Hund bellt ____“

Das Modell berechnet für **jedes mögliche nächste Token** eine Wahrscheinlichkeit.

Mehr macht es nicht. Antworten, Code, Übersetzungen – alles entsteht aus dieser einen Fähigkeit.

Erfundene Beispielwerte



Token für Token – eine Schleife



```
tokens = tokenize("Der Hund bellt")
for _ in range(20):
    p = modell(tokens)      # 20-mal wiederholen
    t = wuerfeln(p)         # Prozent für jedes Token
    tokens.append(t)        # eins auslosen
    tokens.append(t)        # hinten anhängen
print(detokenize(tokens))
```

Python-Pseudocode

Darum erscheinen Antworten Wort für Wort.

Und darum kostet jedes Token Rechenzeit:
Pro Token läuft das ganze Modell einmal durch.

Was ist ein Token?

Text wird in Stücke zerlegt – häufige Wörter ganz, seltene in Teilen:



Beispielhafte Zerlegung – jeder Tokenizer zerlegt anders.

Vokabular

Die feste Liste aller Tokens, die das Modell kennt – wie ein Wörterbuch.
Z. B. 32.000 (Llama 2) oder rund 128.000 (Llama 3).

Token-ID

Jedes Token hat eine Nummer. Das Modell sieht nur diese Nummern.

Faustregel

Englisch ca. 4 Zeichen pro Token,
Deutsch braucht meist mehr Tokens

Live-Demo: Was kommt als Nächstes?

```
import torch
from transformers import AutoTokenizer, AutoModelForCausalLM

tok = AutoTokenizer.from_pretrained("gpt2")
model = AutoModelForCausalLM.from_pretrained("gpt2")

ids = tok("The dog barked", return_tensors="pt").input_ids
with torch.no_grad():
    logits = model(ids).logits[0, -1]
    probs = torch.softmax(logits, dim=-1)

top = torch.topk(probs, 5)
for p, i in zip(top.values, top.indices):
    print(f"{tok.decode(i)!r:>12} {p.item():.1%}")
```

Was die Demo zeigt

Die fünf wahrscheinlichsten
nächsten Tokens mit Prozentwerten
– echt, nicht erfunden.

Voraussetzung

```
pip install torch
transformers
```

*GPT-2 ist klein, alt und englisch –
ideal für eine schnelle Demo.*

Vektor = Array

Vektor = eine Liste von Zahlen


Geometrisch: ein Pfeil vom Nullpunkt aus

```
hund = np.array([0.9, 0.1])
```

4096

Werte pro Token – wie die Kategorien auf einer Quartett-Karte
(z. B. 7B-Modell)

*Ein Vektor pro Token, darin eine Zahl pro Kategorie – bei allen Tokens
dieselben 4096 Kategorien.*




Bedeutung als Richtung

Wort	tierisch	technisch
Hund	0,9	0,1
Katze	0,8	0,2
Auto	0,1	0,9

Erfundene Beispielwerte

Ähnliche Bedeutung = **ähnliche Richtung**




Rechnen mit Bedeutung

König – Mann + Frau $\approx$ Königin

1. Von „Mann“ zu „Frau“ ist ein Schritt in eine bestimmte Richtung (**grün**).
2. Geht man denselben Schritt von „König“ aus ...
3. ... landet man bei „Königin“.

Mit Bedeutung kann man rechnen.

Erfundene Achsen und Werte. Das Beispiel stammt aus word2vec (2013) – bei heutigen LLMs ist es nicht so sauber.



Skalarprodukt = Ähnlichkeit



Paarweise multiplizieren, dann addieren

$$\begin{bmatrix} 0,9 \\ 0,1 \end{bmatrix}_{\text{Hund}} \cdot \begin{bmatrix} 0,8 \\ 0,2 \end{bmatrix}_{\text{Katze}} = 0,9 \cdot 0,8 + 0,1 \cdot 0,2 = 0,74$$

$$\begin{bmatrix} 0,9 \\ 0,1 \end{bmatrix}_{\text{Hund}} \cdot \begin{bmatrix} 0,1 \\ 0,9 \end{bmatrix}_{\text{Auto}} = 0,9 \cdot 0,1 + 0,1 \cdot 0,9 = 0,18$$

Positiv: ähnlich · **Null:** senkrecht · **Negativ:** entgegengesetzt

Die Rechnung als Code steht im Backup.



Grafik: 3Blue1Brown – [3blue1brown.com/lessons/dot-products](https://www.3blue1brown.com/lessons/dot-products)

Gleiches Wort, andere Bedeutung

„Am Fluss steht eine Bank.“


Sitzbank

„Ich bringe mein Geld zur Bank.“

Geldinstitut

Problem: Am Anfang hat jedes Token genau einen Vektor aus der Tabelle (Backup-Folie 48) – „Bank“ also in beiden Sätzen denselben.

Aufgabe der Attention: Den Kontext einrechnen – danach unterscheiden sich die beiden „Bank“-Vektoren.



Grafik: 3Blue1Brown – [3blue1brown.com/lessons/attention](https://www.3blue1brown.com/lessons/attention)

Die Idee: Jedes Wort stellt eine Frage



Query

Was suche ich?

„Bank“ sucht sinngemäß: Wer verrät mir, welche Bank ich bin?



Key

Was biete ich an?

„Fluss“ zeigt sinngemäß: Ich sage etwas über die Umgebung.



Value

Was gebe ich weiter?

Was „Fluss“ an „Bank“ weitergibt: Hier geht es um Natur.

Bild dazu

Jedes Wort hält einen Suchzettel hoch (Query) und trägt ein Namensschild (Key). Passen Zettel und Schild gut zusammen, bekommt das Wort viel von der Information des anderen (Value).

Die Texte auf den Karten sind eine Veranschaulichung – im Modell sind Query, Key und Value nur Zahlen.

Der Transformer: alles zusammen



96

Schichten

96

Attention-Köpfe pro Schicht

≈ 58 Mrd.

Parameter nur für Attention

≈ 1/3

der 175 Mrd. insgesamt

Transformer = der Bauplan heutiger Sprachmodelle: Attention und Feed-Forward als Paar, viele Male hintereinander (GPT-3: 96-mal). Das „T“ in GPT steht dafür.

Feed-Forward = die Netzschicht aus Backup-Folie 49 (verzerren + krümmen).

Zahlen für GPT-3, nach 3Blue1Brown, Deep Learning Kap. 6

Ein gezinkter Würfel mit Zehntausenden Seiten

Wahrscheinlichkeitsverteilung

Jeder Wert liegt zwischen 0 und 1. Alle Werte zusammen ergeben genau 1.

Normaler Würfel


Sechs Seiten, jede mit $1/6 \approx 16,7\%$

32.000

Seiten hat der „Würfel“ eines LLM, z. B. bei Llama 2 – eine pro Token im Vokabular.

Und er ist gezinkt: Die Seiten haben je nach Kontext völlig unterschiedliche Wahrscheinlichkeiten.

Temperature: wie mutig darf das Modell sein?



Logits durch T teilen, dann Softmax

```
softmax(logits / T)
```

T niedrig: fast immer das Wahrscheinlichste – vorhersehbar, gut für Code

T hoch: Unwahrscheinliches kommt öfter dran – kreativer, aber riskanter

Würfel: warum Antworten variieren

Greedy

Immer das wahrscheinlichste Token.
Gleiche Frage, gleiche Antwort – aber oft eintönig.

Sampling

Würfeln nach Verteilung.
Abwechslungsreich – deshalb unterschiedliche Antworten.

Top-p

Nur unter den wahrscheinlichsten Tokens würfeln, die zusammen z. B. 90 % ausmachen.

```
rng = np.random.default_rng()
tokens = ["laut", "leise", "Banane"]
p = softmax(logits / T)
rng.choice(tokens, p=p)      # Sampling
tokens[np.argmax(p)]         # Greedy
```

Ein „falsches“ Token früh in der Antwort verändert alles danach – die Schleife aus Folie 7 baut darauf auf.

Drei Trainingsphasen

1 · Pre-Training

Riesige Textmengen aus Web, Büchern, Code. Ergebnis: Sprache und Weltwissen.

Llama 3: über 15 Billionen Tokens (laut Meta). Wochen bis Monate auf Tausenden GPUs.

2 · Supervised Fine-Tuning

Beispieldialoge: Frage und gute Antwort. Ergebnis: verhält sich wie ein Assistent.

Viel weniger Daten, viel weniger Rechenzeit.

3 · Preference-Tuning

Antworten werden verglichen: Welche ist besser? (RLHF, DPO). Ergebnis: hilfreicher, sicherer.

Bewertungen durch Menschen oder andere Modelle.

Phase 1 kostet den Löwenanteil an Rechenzeit. Phasen 2 und 3 formen das Verhalten.

Basismodell vs. Chatmodell

Eingabe: „Wie koche ich Nudeln?“

Nach Phase 1 (Basismodell)

„Wie koche ich Reis? Wie koche ich Kartoffeln? Diese und weitere Fragen beantworten wir in unserem Kochforum ...“

→ setzt den Text fort, als wäre es eine Webseite

Nach Phase 2 und 3 (Chatmodell)

„Bring Wasser zum Kochen, salze es, gib die Nudeln hinein und koche sie nach Packungsangabe ...“

→ beantwortet die Frage

Schematische Beispiele

Ein Stück weniger Blackbox

1 **Ein LLM sagt das nächste Token vorher**
eine Wahrscheinlichkeit für jedes mögliche Token, in einer Schleife

2 **Wörter sind Vektoren**
Bedeutung ist eine Richtung im Raum, Ähnlichkeit ein Skalarprodukt

3 **Attention rechnet den Kontext ein**
aus „Bank“ wird „Bank am Fluss“

4 **Wahrscheinlichkeit plus Würfeln**
deshalb variieren Antworten, auch bei gleicher Frage

5 **Pretraining, dann Chat-Training**
aus einem Textfortsetzer wird ein Assistent

Nächster Abschnitt: Wie wird aus einem Modell ein Werkzeug?

Was man erwartet, und was wirklich ist

DIE ERWARTUNG


Ein Prozess, der mich kennt
Eine Session, die mitschreibt
Ein Gedächtnis im Modell
Eine Datenbank dahinter
Ein System, das aus dem Gespräch lernt

DIE REALITÄT

Ein Funktionsaufruf ohne Zustand
Kein Session-Handle, keine ID
Kein Byte Speicher auf Modellseite
Keine Datenbank, kein Dateisystem
Gewichte sind read-only

Der Vergleich, der bei Datenbank-Entwicklern sitzt: Es ist ein Stored-Procedure-Aufruf ohne Session-State.

Der Request-Zyklus



Der Rückweg ist die Pointe: Die Antwort landet nicht in einer Session beim Anbieter, sondern in deinem Speicher.

Die Wahrheit auf dem Draht

```
{ "model": "claude-opus-5", "max_tokens": 16000,
  "system": "Du bist ein Assistent für PowerBuilder-Code. <projektregeln>...</projektregeln>",
  "tools": [ { "name": "read_file", ... }, { "name": "write_file", ... } ],
  "messages": [
    { "role": "user",      "content": "Öffne w_main_order." },           // Turn 1
    { "role": "assistant", "content": [ { "type": "tool_use", ... } ] },
    { "role": "user",      "content": [ { "type": "tool_result", ... } ] },
    { "role": "assistant", "content": "Das Fenster hat 14 Events ..." },
    { "role": "user",      "content": "Und was macht cb_close?" }       // Turn 3, neu
  ] }
```

KEIN ZUSTAND BEIM ANBIETER

Keine Session-ID, keine Konversations-ID. Turn 1 steckt noch in jedem folgenden Request: ein selbsttragendes Dokument.

Beweis in dreißig Sekunden

● Mit Historie

```
messages: [  
  user:      "Mein Name ist Ludwin."  
  assistant: "Hallo Ludwin!"  
  user:      "Wie heiße ich?"  
]
```

„Du heißt Ludwin.“

● Ohne Historie


```
messages: [  
  user:      "Wie heiße ich?"  
]
```

„Das weiß ich nicht.“

Derselbe Aufruf, dasselbe Modell. Das Gedächtnis liegt vollständig in den Zeilen, die du mitschickst.

Das Kontextfenster ist ein Budget

Maximale Größe eines einzelnen Requests: 1 Million Token (aktuelle Claude-Modelle; Haiku 4.5: 200.000)



Alles zusammen darf das Fenster nicht überschreiten

● **Compaction**

Ältere Teile der Historie werden zu einer Zusammenfassung verdichtet. Verlustbehaftet, aber der Faden bleibt.

● **Context Editing**

Alte Tool-Ergebnisse und Denk-Blöcke werden entfernt. Die Struktur bleibt, die Details sind weg.

Beides sind Eingriffe in ein Array, das deine Software hält. Deshalb funktionieren sie überhaupt.

Prompt-Caching: der Präfix-Abgleich

FALL A: STABILER ANFANG



FALL B: ZEITSTEMPEL AM ANFANG



MERKSATZ

Stabiles nach vorne, Veränderliches nach hinten. Ein `datetime.now()` im System-Prompt kostet keine Fehlermeldung, nur eine höhere Rechnung.

Wer schreibt eigentlich die Datei?

ANTWORT

Das Modell ändert nie eine Datei. Es erzeugt Text, der einen Änderungswunsch beschreibt. Die Datei schreibt deine Software.

• Tool = Beschreibung

Ein Tool ist nur eine Beschreibung: Name, Zweck und JSON-Schema der Parameter. Kein Code, keine Referenz, keine Verbindung.

• Antwort = tool_use

Die Antwort enthält einen tool_use-Block. Semantisch ein Funktionsaufruf, physikalisch ein Stück JSON im Text.

• Dokument = Tool-Ausgabe


Dokumente sind Tool-Ausgaben. Eine Excel-Datei entsteht nicht im Modell, sondern durch eine normale Bibliothek in deiner Umgebung.

Ein Agent ist eine Schleife

SCHREIBT NICHTS

DEIN CODE


SEITENEFFEKT



SCHLEIFE, BIS DAS MODELL `stop_reason: end_turn` MELDET

Workflow: dein Code bestimmt die Schritte. **Agent:** das Modell bestimmt sie. Flexibel, aber teurer und langsamer.

Anatomie von Claude Code



Der Ablauf, Schritt für Schritt

1

Eingabe anhängen

Das Frontend hängt deine Zeile an `messages[]` an.

2

Kontext einlesen

Prompt, Projektregeln, Memory, Skills, Tools, Historie.

3

Übergeben

Alles wird zu einem einzigen JSON-Request.

4

Senden

Der Loop schickt ihn an die API. Ab hier nichts mehr bei dir.

5

Antwort

Text oder `tool_use`. Das Modell hat nichts getan, nur beschrieben.

6

Prüfen

Pfad erlaubt? Rückfrage nötig? Hooks können blocken.

7

Ausführen

Erst jetzt läuft echter Code, deiner.

8

Wirken

Datei geschrieben, Kommando gelaufen. Nur hier Seiteneffekte.

9

Zurückmelden

Ergebnis, auch Fehler, als `tool_result` an die Historie. Weiter bei 2.

10

Anzeigen

Kommt Text statt Werkzeugaufruf, endet die Schleife.

Fallbeispiel: eine echte Frage

„Woher kommt die E-Mail-Adresse, an die die Rechnungen versendet werden?“

● Ein altes Projekt

Rund 20 Jahre gewachsenes PowerBuilder-Projekt mit Oracle-Packages.

● Keine einzelne Datei

Die Antwort steht in keiner Datei vollständig. Eine Suche reicht nicht.

● Eine Kette

PowerBuilder-Aufruf → Oracle-Package → zur Laufzeit gebautes SQL.

Echter Mitschnitt eines Agent-Laufs. Objektnamen sind neutralisiert.

Fünf Runden für eine Antwort

RUNDE · WERKZEUGAUFRUF

WAS ZURÜCKKAM

KONTEXT WÄCHST

1

Grep "of_sendmail"
ganzes Repository

21 Dateien, meist in billing.pbl



2

Grep "mail"
nur n_cst_bill_output.sru

60 Treffer. Empfänger kommt aus Tabelle CONTACT



3

Grep "get_primary_contact"
ganzes Repository

Treffer in PowerBuilder und in Oracle-Packages



4

Read PCK_COMMON.pkb
Zeilen 1695–1749

Die Prozedur samt dynamischem SQL



5

Antwort formulieren
stop_reason: end_turn

belegt, keine weitere Suche nötig



Die Antwort und ein versteckter Befund

Die Adresse steht in `CONTACT . CONTACT_EMAIL`, ausgewählt von einer Oracle-Prozedur, nicht im PowerBuilder-Code.

1

`n_cst_bill_output.sru:3870`
ruft `get_primary_contact` auf

2

`PCK_COMMON.pkb:1700`
baut daraus ein dynamisches SQL-Statement

3

`get_mail_and_address`
liefert Adresse und Anrede zum gewählten Kontakt

```
SELECT contact_num FROM contact
WHERE customer_num = '...'
      AND pck_common.is_valid_mail(
            contact_email) = '1'

ORDER BY
  DECODE(contact_is_default_inv,'1',1,2),
  DECODE(contact_is_default_del,'1',1,2),
  DECODE(contact_is_default_lab,'1',1,2)
```

DER NICHT OFFENSICHTLICHE BEFUND

Die Flag-Spalten sortieren, sie filtern nicht. Einzige harte Bedingung ist eine gültige Adresse.

Ohne gesetztes Flag geht die Mail trotzdem an den ersten Kontakt. Länge 9 des Schlüssels entscheidet über die Rolle: Kunde oder Lieferant.

Was dieses Beispiel zeigt

● Der Loop dreht, bis er fertig ist

Fünf API-Aufrufe für eine Frage.
Wer Kosten oder Latenz schätzt,
zählt Runden, nicht Fragen.

● Der Kontext wächst

Runde 5 schickt alles aus Runde 1
bis 4 mit. Mit Prompt-Caching etwa
ein Zehntel der Kosten.

● Kein Index, kein Embedding


Vier gezielte grep-Suchen und ein
Dateiauszug. Kein Index, der bei
jedem Commit veraltet.

DIE POINTE

Das Modell hat keine einzige Datei geöffnet. Es hat viermal beschrieben, was zu tun wäre. Gelesen hat deine Harness.

Nachprüfbar ist das Ergebnis, weil jede Aussage Datei und Zeile nennt. Nicht, weil man dem Modell vertrauen müsste.

RAG: erst nachschlagen, dann antworten



- **Retrieval: suchen**

Findet zur Frage die passenden Ausschnitte aus Code und Dokumentation.

- **Generation: antworten**

Das Sprachmodell formuliert die Antwort nur aus diesen Ausschnitten.

DIE VEKTORDATENBANK GEHÖRT NICHT ZUM MODELL

Sie ist Infrastruktur daneben. Claude Code durchsucht Code übrigens mit grep statt mit Embeddings. Praxis und Aufbau: Teil 2.

Drei Grenzen – direkt aus dem Aufbau erklärbar

Halluzinationen

Das Modell erzeugt plausible Fortsetzungen, keine geprüften Fakten. Plausibel klingender Unsinn ist auch plausibel.


Wissensstichtag

Gelernt wird nur bis zum Ende der Trainingsdaten. Alles danach kennt das Modell nicht.

Kontextfenster

Nur begrenzt viele Tokens passen gleichzeitig hinein.

Warum das Kontextfenster teuer ist: Das Attention-Muster hat eine Zeile und eine Spalte pro Token – doppelt so viel Text heißt viermal so viele Scores.



Grafik: 3Blue1Brown – 3blue1brown.com/lessons/attention

Halluzination, mechanisch erklärt

MECHANISMUS

Das Modell ist darauf trainiert, plausible Fortsetzungen zu erzeugen, nicht wahre. Es gibt keinen Schritt, in dem etwas nachgeschlagen oder verifiziert wird.

● Souverän, auch wenn falsch

Das Modell unterscheidet intern nicht zwischen „das weiß ich“ und „dieses Muster passt“.

● Besonders anfällig

Exakte, seltene Fakten mit vorhersagbarer Form: Versionsnummern, Paragraphen, API-Signaturen.

● Im Alltag

Eine plausibel klingende, aber nicht existierende Methode eines PowerBuilder-Objekts.

Was hilft, und was nicht

„Erfinde nichts“ in den Prompt

Das Modell erkennt den Unterschied nicht

Schwach

Quellen in den Kontext legen (RAG)

Vorlegen statt Nachschlagen

Stark

Prüf-Werkzeuge geben

Datei lesen, Test ausführen: gegen die Realität prüfen

Am stärksten

Ausgabe gegen Schema validieren

Fängt Formfehler, nicht Inhaltsfehler

Teilweise


Nach der Quelle fragen

Ohne Retrieval wird die Quelle mit erfunden

Riskant

Nicht schärfer bitten, sondern nachprüfbar machen.

Prompt Injection: ein Strom, drei Herkünfte




Wer irgendwo Text platzieren kann, den die KI später liest, kann versuchen, Anweisungen einzuschmuggeln.

Die gefährliche Kombination, und was hilft



Beispiel: ein Agent, der Support-Mails liest und Schreibrechte auf die Datenbank hat.



Vollständig verhindern lässt sich das nicht, es folgt aus der Architektur. Man begrenzt den Schaden.

Wir sehen jede Zahl – und verstehen wenig

175 Mrd.

Parameter bei GPT-3. Jeder einzelne Wert ist sichtbar – aber was er bedeutet, steht nirgends.

Bedeutung ist verteilt: Ein Konzept steckt in vielen Gewichten, und jedes Gewicht hilft bei vielen Konzepten.

Interpretierbarkeit

Forschung versucht, einzelne „Features“ im Inneren zu finden.

Beispiel: Anthropic hat 2024 Millionen solcher Features in Claude 3 Sonnet identifiziert, darunter eines für die Golden Gate Bridge. Wurde es künstlich verstärkt, bezog das Modell fast jedes Gespräch auf die Brücke.

Das ist ein Anfang – kein vollständiges Verständnis.

Was heißt das für PowerBuilder-Entwickler?

PowerScript ist Nische

Vermutlich nur ein kleiner Teil der Trainingsdaten – eine plausible Annahme, keine Messung. Ergebnisse können schwächer sein als bei Java oder C#.

Kontext statt Hoffnung

DataWindow-Definition, Vorfahren-Objekte und Fehlermeldung mitschicken. Das Modell kennt euer Projekt nicht.

RAG vor Fine-Tuning

Eigenen Code per Embedding durchsuchbar machen ist meist günstiger als ein eigenes Modell zu trainieren.

Datenschutz

Firmencode an eine Cloud-API oder lokal mit offenen Modellen? Eine bewusste Entscheidung pro Projekt.

Drei Dinge zum Mitnehmen

- 1 Der Kontext ist die Anwendung**
Was ihr baut, ist der Zusammensteller des Requests, nicht das Modell. Dort liegen Wertschöpfung, Kosten und Fehler.
- 2 Nachprüfbar statt eindringlich**
Gegen Halluzination und Zufall hilft nicht der schärfere Prompt, sondern Prüfung in gewöhnlichem Code: Tools, Schema, Tests.
- 3 Modellausgaben sind nicht vertrauenswürdig**
Behandelt sie wie Nutzereingaben: minimale Rechte, Bestätigung für Unumkehrbares, Validierung, Protokoll.

Und wenn der Code das Haus nicht verlassen darf?

Teil 2: Lokale LLMs für PowerBuilder, von der Theorie zur Praxis

Fragen?

Zum Weiterlernen

3Blue1Brown

Essence of Linear Algebra · Deep Learning, Kap. 5–7

Stanford CS224N

Natural Language Processing with Deep Learning

Andrej Karpathy

„Let's build GPT: from scratch, in code, spelled out“

Matrix = Tabelle und Abbildung


Rechnerisch: Tabelle aus Zahlen

131 Mio.

Zahlen in der Embedding-Tabelle eines 7B-Modells
z. B. 32.000 Zeilen (eine pro Token) $\times$ 4096 Spalten (die
Zahlen pro Token, Folie 10)

Token-ID = Zeilennummer – ein Lookup, nichts
Magisches

Geometrisch: verschiebt den ganzen Raum



Grafik: 3Blue1Brown – [3blue1brown.com/lessons/linear-transformations](https://www.3blue1brown.com/lessons/linear-transformations)

Wozu? Durch Verzerren rückt Zusammengehöriges näher
zusammen und Unterschiedliches weiter auseinander.

Eine Netzschicht = verzerren + krümmen

Schritt 1 – Verzerren: $y = W \cdot x$ mit $x = (2, 3)$


W		Rechnung	y
1	0	$1 \cdot 2 + 0 \cdot 3$	2
1	1	$1 \cdot 2 + 1 \cdot 3$	5
1	-1	$1 \cdot 2 - 1 \cdot 3$	-1

Schritt 2 – Krümmen (Aktivierung, z. B. ReLU): negative Werte $\rightarrow 0$


(2, 5, -1) $\rightarrow$ (2, 5, 0)

W = Gewichte (Weights) · ca. 17 Mio. davon pro 4096×4096-Matrix

Matrix: verzerrt



Aktivierung: krümmt



Grafik: 3Blue1Brown – [3blue1brown.com/lessons/linear-transformations](https://www.3blue1brown.com/lessons/linear-transformations)

Backup: Skalarprodukt im Code

```
def skalarprodukt(a, b):  
    summe = 0  
    for x, y in zip(a, b):  
        summe += x * y  
    return summe          # NumPy: a @ b
```

● Hund · Katze

$0,9 \cdot 0,8 + 0,1 \cdot 0,2 = 0,74$. Ähnlich.

● Hund · Auto

$0,9 \cdot 0,1 + 0,1 \cdot 0,9 = 0,18$. Kaum ähnlich.

Die Rechnung: Skalarprodukt + Softmax

1. Score = Query · Key

Skalarprodukt aus Folie 13: Wie gut passt jedes Wort zu „Bank“?

2. Softmax

macht aus Zahlen Prozentwerte mit Summe 100 % (Backup-Folie 54)


3. Mischen

Values nach Gewicht aufsummieren und zu „Bank“ addieren

Am	Fluss	steht	eine	Bank
0,2	2,0	0,5	0,3	1,0

Scores aus Sicht von „Bank“ – erfundene Werte

Gewichte nach Softmax




Das Attention-Muster



Scores: Jeder Punkt ist ein Skalarprodukt. Großer Punkt = passt gut.

Grafik: 3Blue1Brown – [3blue1brown.com/lessons/attention](https://www.3blue1brown.com/lessons/attention)



Nach Softmax: Jede Spalte ergibt zusammen 1 – das Attention-Muster.

Nur nach links schauen

Unnormalized
Attention Pattern

+3.53	+0.80	+1.96	+4.48	+3.74	-1.95
$-\infty$	-0.30	-0.21	+0.82	+0.29	+2.91
$-\infty$	$-\infty$	+0.89	+0.67	+2.99	-0.41
$-\infty$	$-\infty$	$-\infty$	+1.31	+1.73	-1.48
$-\infty$	$-\infty$	$-\infty$	$-\infty$	+3.07	+2.94
$-\infty$	$-\infty$	$-\infty$	$-\infty$	$-\infty$	+0.31

softmax
→

Normalized
Attention Pattern

1.00	0.75	0.69	0.92	0.46	0.00
0.00	0.25	0.08	0.02	0.01	0.46
0.00	0.00	0.24	0.02	0.22	0.02
0.00	0.00	0.00	0.04	0.06	0.01
0.00	0.00	0.00	0.00	0.24	0.48
0.00	0.00	0.00	0.00	0.00	0.03

Grafik: 3Blue1Brown – [3blue1brown.com/lessons/attention](https://www.3blue1brown.com/lessons/attention)

Maskierung: Jedes Wort sieht nur die Wörter davor – beim Schreiben gibt es die späteren ja noch nicht (Folie 7).

```
scores = Q @ K.T / np.sqrt(d_k)
scores += maske # Zukunft: -inf
gewichte = softmax(scores) # je Zeile 1
delta = gewichte @ V
E_neu = E + delta
```

Das ist die ganze Attention.

Fünf Zeilen NumPy, vereinfacht. Echte Modelle rechnen dasselbe – nur mit riesigen Matrizen und vielen Köpfen parallel.

Softmax macht Wahrscheinlichkeiten

Das Modell liefert beliebige Zahlen (Logits). Softmax macht daraus eine Verteilung:


Token	Logit	e^{Logit}	÷ Summe
laut	2,0	7,39	66 %
leise	1,0	2,72	24 %
Banane	0,1	1,11	10 %
Summe		11,21	100 %

e^x macht alles positiv und betont Unterschiede.
÷ **Summe** sorgt dafür, dass alles 1 ergibt.

```
def softmax(z):  
    e = np.exp(z - z.max())  
    return e / e.sum()  
  
softmax(np.array([2.0, 1.0, 0.1]))  
# -> [0.66, 0.24, 0.10]
```

„ $z - z.max()$ “ ändert das Ergebnis nicht, verhindert aber zu große Zahlen.

Cross-Entropy: wie überrascht war das Modell?



```
loss = -np.log(p[richtig])
```

99 % → 0,01


66 % → 0,42

10 % → 2,30

Zufälliges Raten bei 32.000 Tokens: Loss $\approx$ 10,4

Training = diesen Wert über Billionen Tokens senken

Lernen = viele kleine Korrekturen



Schematische Trainingskurve – Startwert $\approx 10,4$ wie in Backup-Folie 55

Das Mischpult

Milliarden Regler (Gewichte), anfangs zufällig eingestellt.

Der Gradient

sagt für jeden Regler: In welche Richtung drehen, damit der Loss sinkt?

Backpropagation


berechnet alle Gradienten in einem Rückwärtsdurchlauf (Kettenregel).

Die Trainingsschleife in PyTorch

```
opt = torch.optim.AdamW(modell.parameters(), lr=3e-4)

for eingabe, ziel in daten: # ziel: 1 Token versetzt
    logits = modell(eingabe)
    loss = F.cross_entropy(
        logits.view(-1, logits.size(-1)),
        ziel.view(-1))
    loss.backward() # Gradienten
    opt.step()      # Regler drehen
    opt.zero_grad()
```

Kein Mensch schreibt Regeln – das Modell lernt nur aus „Was kommt als Nächstes?“.



Grafik: 3Blue1Brown – [3blue1brown.com/lessons/attention](https://www.youtube.com/watch?v=3blue1brown.com/lessons/attention)

Jede Position im Text ist ein eigenes Trainingsbeispiel – ein Satz trainiert viele Vorhersagen auf einmal.

Backup: Netzschicht in NumPy und PyTorch

```
import numpy as np

W = np.array([[1, 0], [1, 1], [1, -1]])
x = np.array([2, 3])
y = W @ x          # [ 2  5 -1]  verzerren
y = np.maximum(y, 0) # [ 2  5  0]  krümmen (ReLU)

import torch
schicht = torch.nn.Linear(4096, 4096)
z = torch.relu(schicht(torch.randn(4096)))
```

NumPy: das Zahlenbeispiel von Backup-Folie 49

PyTorch: eine echte Schicht mit $4096 \times 4096 \approx 16,8$ Mio. Gewichten (plus 4096 Bias-Werte)

Glossar (1/2): Bausteine

Token · Folie 8

Textstück (Wort oder Wortteil) mit einer Nummer. Das Modell sieht nur diese Nummern.

Vektor · Folie 10

Liste von Zahlen – geometrisch ein Pfeil vom Nullpunkt aus.

Embedding · Folie 10

Der Vektor eines Tokens – wie eine Quartett-Karte mit z. B. 4096 Kategorien.

Skalarprodukt · Folie 13

Paarweise multiplizieren, dann addieren. Misst, wie ähnlich zwei Vektoren sind.

Matrix · Backup-Folie 48

Tabelle aus Zahlen. Mit einem Vektor multipliziert, verzerrt sie den Raum.

Gewichte (W), Parameter · Backup-Folie 49

Die einstellbaren Zahlen im Modell, die „Regler“. Werden beim Training gelernt.

Aktivierung (ReLU, GELU, SwiGLU) · Backup-Folie 49

Einfache Regel, die den Raum „krümmt“, z. B. negative Werte $\rightarrow 0$.

Schicht · Backup-Folie 49

Ein Verarbeitungsschritt. Im Transformer: Attention + Feed-Forward (Folie 16).

Attention · Folie 14

Rechnet den Kontext in den Vektor eines Wortes ein: aus „Bank“ wird „Bank am Fluss“.

Query, Key, Value · Folie 15

Drei Vektoren pro Token: Was suche ich? Was biete ich an? Was gebe ich weiter?

Maskierung · Backup-Folie 53

Jedes Wort darf nur auf Wörter davor schauen, nicht auf spätere.

Attention-Kopf · Folie 16

Ein eigener Satz Q-, K- und V-Matrizen. Viele Köpfe arbeiten parallel.

Glossar (2/2): Wahrscheinlichkeit, Training, Praxis

Logits · Backup-Folie 54

Rohpunkte des Modells pro Token, vor der Umrechnung in Prozent.

Softmax · Backup-Folie 54

Macht aus Rohpunkten Prozentwerte mit Summe 100 %.

Temperature · Folie 18

„Risikofreude-Regler“: niedrig = vorsichtig, hoch = experimentierfreudig.

Sampling · Folie 19

Das nächste Token wird nach der Verteilung ausgewürfelt.

Loss · Backup-Folie 55

Fehlerwert: eine Zahl, wie schlecht das Modell vorhersagt. Training senkt sie.

Cross-Entropy · Backup-Folie 55

„Überraschungsmaß“: –In der Wahrscheinlichkeit, die das richtige Token bekam.

Gradient, Backpropagation · Backup-Folie 56

Gradient: in welche Richtung jeder Regler gedreht wird. Backpropagation berechnet ihn.

Pre-Training, Fine-Tuning · Folie 20

Erst Wissen aus riesigen Textmengen, dann Assistenten-Verhalten aus Beispieldialogen.

RLHF, DPO · Folie 20

Lernen aus Vergleichen „Antwort A ist besser als B“ – mit oder ohne Bewertungsmodell.

Kontextfenster · Folie 38

Wie viele Tokens das Modell gleichzeitig sehen kann.

Halluzination · Folie 38

Plausibel klingende, aber falsche Ausgabe.

RAG · Backup

Retrieval-Augmented Generation: erst passende Dokumente suchen, dann mit der Frage ans Modell.

Backup: Sub-Agenten und MCP

● Sub-Agenten

Ein eigener Aufruf mit eigenem, frischem Kontextfenster.
Er sieht die Konversation des Orchestrators nicht.
Austausch nur über Text; geteilt wird nur das Dateisystem.

● MCP

Das Model Context Protocol standardisiert, wie eine Harness Tools von externen Anbietern einbindet. Das Modell sieht am Ende wieder nur Tool-Beschreibungen.

PRAXISREGEL

Jeder Auftrag an einen Sub-Agenten muss selbsttragend sein: Pfade, Randbedingungen und gewünschtes Berichtsformat. Er kann nicht nachfragen.

Backup: Kontext-Rot

● Positionseffekte

Informationen am Anfang und am Ende werden zuverlässiger genutzt als solche in der Mitte. Eine wichtige Anweisung im 200-Seiten-Anhang wirkt kaum.

● Verdünnung

Je mehr irrelevanter Text mitkommt, desto schwächer wirkt der relevante. „Alles reinwerfen“ funktioniert schlechter als eine gute Auswahl.

PRAXISRATSCHLAG

Bei langen Kontexten die Aufgabenstellung nach dem Material platzieren: Sie steht an einer zuverlässigen Position, und das Material bildet einen stabilen, cachebaren Präfix.

Backup: Garantiert gültiges JSON



PRO TOKEN NEU: DIE MASKE KENNT DEN AKTUELLEN SCHEMA-ZUSTAND

WICHTIGE ABGRENZUNG

Garantiert wird die Struktur, nicht die Richtigkeit. Das Feld „betrag“ ist sicher eine Zahl. Ob es die richtige ist, sagt das Schema nicht.

Backup: Warum die erste Antwort dauert

ERSTES TOKEN SICHTBAR

Prefill

Kontext parallel verarbeitet

1

2

3

4

5

6

7

n

SKALIERT MIT EINGABELÄNGE

DECODE: EIN TOKEN JE DURCHLAUF

MERKSATZ

Langer Kontext verzögert den Start. Lange Antworten verlängern das Ende. Streaming ist deshalb kein Feature, sondern Voraussetzung.

Prompt-Caching senkt die Startzeit, nicht nur die Kosten. Agenten multiplizieren alles: zehn Schleifendurchläufe sind zehn vollständige Aufrufe.

Backup: Modell-IDs und Preise

MODELL	ID	KONTEXT	AUSGABE MAX.	PREIS JE MIO. TOKEN
Claude Opus 5	claude-opus-5	1 M	128 K	\$5 / \$25
Claude Sonnet 5	claude-sonnet-5	1 M	128 K	\$3 / \$15
Claude Haiku 4.5	claude-haiku-4-5	200 K	64 K	\$1 / \$5
Claude Fable 5	claude-fable-5	1 M	128 K	\$10 / \$50

ACHTUNG

Zahlen vor dem Vortrag gegenprüfen. Eingabe und Ausgabe kosten unterschiedlich: Ausgabe das Fünffache, Cache-Lesen ein Zehntel.

Skalierung und Emergenz

Skalierungsgesetze

Der Loss sinkt vorhersagbar, wenn man Modellgröße, Daten und Rechenleistung erhöht (Kaplan et al. 2020).

Chinchilla (Hoffmann et al. 2022): Optimal sind grob 20 Trainings-Tokens pro Parameter.

Emergenz – umstritten

Manche Fähigkeiten scheinen erst ab einer bestimmten Größe plötzlich aufzutauchen.

Kritik (Schaeffer et al. 2023): Die Sprünge könnten auch an der Art liegen, wie man misst.

Vorhersagbar ist der Loss – nicht, welche Fähigkeiten genau dabei entstehen.