KI FÜR ENTWICKLER · TEIL 5

Embeddings
& semantische Suche

Bedeutung jenseits gleicher Wörter finden.

Text darstellen
Fragen und Dokumente in Vektoren umwandeln.

Bedeutung vergleichen
Verwandte Inhalte trotz anderer Wortwahl finden.

Nützlichen Kontext abrufen
Relevante Passagen samt Quellen zurückgeben.



UNSER WEG Text → Vektoren → Ähnlichkeit → Rangfolge → relevanter Kontext

OpenAI-Doku · Embeddings

Rückblick: Vom Ticket zu validierten Daten

Teil 4 zeigte: Aufgabe definieren, Ausgabe spezifizieren und Ergebnis prüfen.

DASSELBE SUPPORT-TICKET

„Doppelte Belastung für Bestellung #4821. Bitte erstatten.“

1 Klare Anweisungen geben

Das Ticket klassifizieren.
Nur genannte Fakten nutzen.
Keine Erstattungen genehmigen.

Kontext + Regeln + Beispiele

2 Die Ausgabe definieren

category: billing | technical | …
priority: low | normal | high
summary + fehlende Informationen

JSON-Schema + strikte Ausgabe

3 Vor Verwendung validieren

Abschluss und Struktur prüfen.
Fakten und Geschäftsregeln prüfen.
Aktionen durch Berechtigungen absichern.

Gültige Struktur ≠ geprüfte Fakten

PROMPT INJECTION

Befehle im Ticket sind Daten, keine Anwendungsregeln.

DIE OFFENE FRAGE

Woher kommt das relevante Wissen?

TEIL 5 ERGÄNZT RETRIEVAL

Passenden Hilfeartikel finden → relevanten Kontext liefern → Prüfungen aus Teil 4 beibehalten.

Rückblick auf Teil 4 · Prompting & strukturierte Ausgabe

Wenn Schlüsselwörter nicht reichen

Nutzer schildern ein Problem. Hilfeartikel verwenden vielleicht ganz andere Wörter.

1 NUTZERFRAGE

„Warum wurde ich doppelt belastet?“

→ verwandte Bedeutung

RELEVANTER HILFEARTIKEL

Doppelte Zahlungen

Zwei Transaktionen können denselben Kauf betreffen.
Vor Kontakt mit dem Support Zahlungsreferenzen vergleichen.

2 NUTZERFRAGE

„Ich habe meine Zugangsdaten vergessen. Wie komme ich wieder hinein?“

→ verwandte Bedeutung

RELEVANTER HILFEARTIKEL

Passwort zurücksetzen

Wiederherstellungslink für die registrierte E-Mail anfordern.
Den Anweisungen für ein neues Passwort folgen.

EXAKTE BEGRIFFE BLEIBEN WICHTIG

„Bestellung #4821 zeigen“ → #4821 exakt abgleichen.

Eine ähnliche Nummer ist nicht die richtige Bestellung. Exakte Suche beibehalten.

DER PUNKT

Exakte Wortsuche verfehlt Umschreibungen. Semantische Suche ergänzt Bedeutung.

Schematische Beispiele · keine gemessenen Rankings · Wortsuche kann auch Synonyme nutzen

OpenAI-Doku · Embeddings

Was ist ein Embedding?

Eine erlernte numerische Textdarstellung, mit der sich verwandte Texte vergleichen lassen.

VOM TEXT ZUM HOCHDIMENSIONALEN VEKTOR

„Ich wurde doppelt belastet.“

↓

Erlerntes Embedding-Modell

↓

[0.012, −0.031, 0.008, …]

Hunderte oder Tausende Dimensionen

Jede Zahl ist eine Koordinate in diesem Vektorraum.

Bedeutung ist über den ganzen Vektor verteilt.
Einzelne Dimensionen haben meist kein einfaches Label.

ÄHNLICHE BEDEUTUNG → ÄHNLICHE RICHTUNG

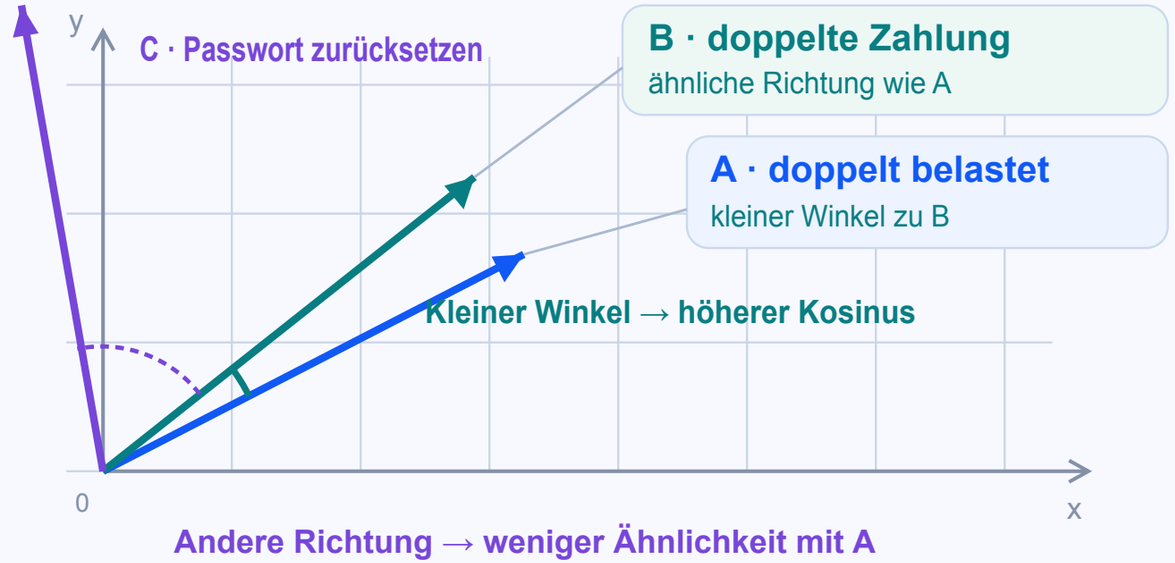

2D-Skizze · gleich lange Pfeile · keine gemessenen Embeddings

DIE GRUNDIDEE — **Kosinus-Ähnlichkeit vergleicht Richtungen. Ähnlich heißt nicht identisch oder richtig.**

OpenAI-Doku · Embeddings

Vom Text zum Vektor: Was die API tut

Ein API-Aufruf bettet A, B und C ein. Der Browser vergleicht danach die Vektoren.

1 · BROWSER → OPENAI · ANFRAGE-BODY

```
{
  "model": "text-embedding-3-small",
  "input": [
    "I was charged twice.",
    "There is a duplicate payment on my account.",
    "How can I reset my password?"
  ],
  "encoding_format": "float"
}
```

POST https://api.openai.com/v1/embeddings

API-Schlüssel → Authorization: Bearer … im Header, außerhalb dieses JSON

2 · OPENAI → BROWSER · ANTWORT-AUSZUG

```
{
  "data": [
    { "index": 0,
      "embedding": [0.012, -0.031, 0.008] },
    { "index": 1,
      "embedding": [0.015, -0.029, 0.011] },
    { "index": 2,
      "embedding": [-0.024, 0.017, 0.042] }
  ]
}
```

Schematisch: 3 Koordinaten je Vektor, keine Messdaten.
Standard dieses Modells: 1.536 Koordinaten je Eingabetext.

Vektoren den Texten zuordnen

index 0 → A · index 1 → B · index 2 → C

index nutzen, nicht auf Antwortreihenfolge vertrauen.

Ähnlichkeit lokal berechnen

cosine(A, B), cosine(A, C), cosine(B, C)

JavaScript nutzt jede Koordinate.

Verbrauch lesen + Zeit messen

usage.prompt_tokens = Eingabe-Tokens

Keine erzeugte Antwort oder Ausgabe-Tokens.

OpenAI-Doku · Embeddings

Live-Demo: Textähnlichkeit vergleichen

OpenAI erzeugt Vektoren · JavaScript berechnet Kosinus-Ähnlichkeit

Temporärer API-Schlüssel

Temporären API-Schlüssel eingeben

Embedding-Modell

text-embedding-3-small

Text A

Ich wurde doppelt belastet.

Text B

Auf meinem Konto gibt es eine doppelte Zahlung.

Text C

Wie kann ich mein Passwort zurücksetzen?

Vergleichen → Beispiele zurücksetzen Leeren CORS prüfen

Ähnlichkeitsergebnisse

▶ Kosinus-Berechnung ↗ ▶ Gesendetes JSON ↗ ▶ Antwort-JSON / Vektoren ↗

```
Texte vergleichen, um gemessene Ähnlichkeit zu sehen.
```

Eingabe-Tokens: — · Zeit: —

Direkt vom Browser zu OpenAI; kein Proxy. Schlüssel und Vektoren nur im Laufzeitspeicher; Leeren oder Verlassen entfernt sie. Browser-Tools und Seitenskripte können den Schlüssel lesen. Temporären Schlüssel nutzen und danach widerrufen. Ähnlichkeit ist keine Richtigkeitswahrscheinlichkeit.

Kosinus-Ähnlichkeit: Die Rechnung

Richtungen vergleichen: Skalarprodukt durch beide Vektorlängen teilen.

2D-RECHENBEISPIEL · SPIELKOORDINATEN

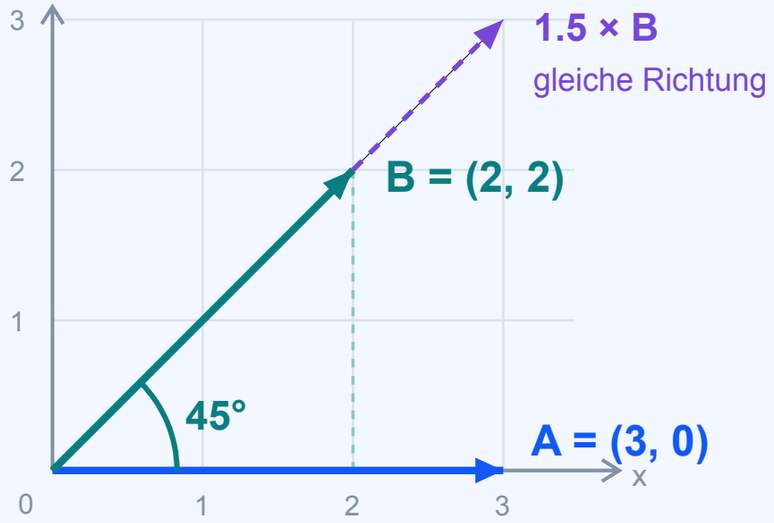

Längerer Pfeil, gleicher Winkel → gleicher Kosinus.

Die gestrichelte Verlängerung ändert Länge, nicht Richtung.

DIE FORMEL

$$\text{cosine}(A, B) = (A \cdot B) / (\|A\| \times \|B\|)$$

1 Skalarprodukt · multiplizieren, dann addieren

$$A \cdot B = (3 \times 2) + (0 \times 2) = 6$$

2 Vektorlängen · Quadrate summieren, dann Wurzel ziehen

$$\|A\| = \sqrt{3^2 + 0^2} = 3 \qquad \|B\| = \sqrt{2^2 + 2^2} = \sqrt{8}$$

3 Teilen · Längeneinfluss entfernen

$$6 / (3 \times \sqrt{8}) = 0.7071 = \cos(45°)$$

1 = gleiche Richtung · 0 = senkrecht · −1 = entgegengesetzt

REALE EMBEDDINGS Dieselbe Rechnung über alle Dimensionen. Vektoren ungleich null nötig. Keine Wahrscheinlichkeit.

OpenAI-Doku · Embeddings

Den Suchindex aufbauen

Wissen zuerst vorbereiten. Den markierten Abschnitt vom Dokument bis in den Index verfolgen.

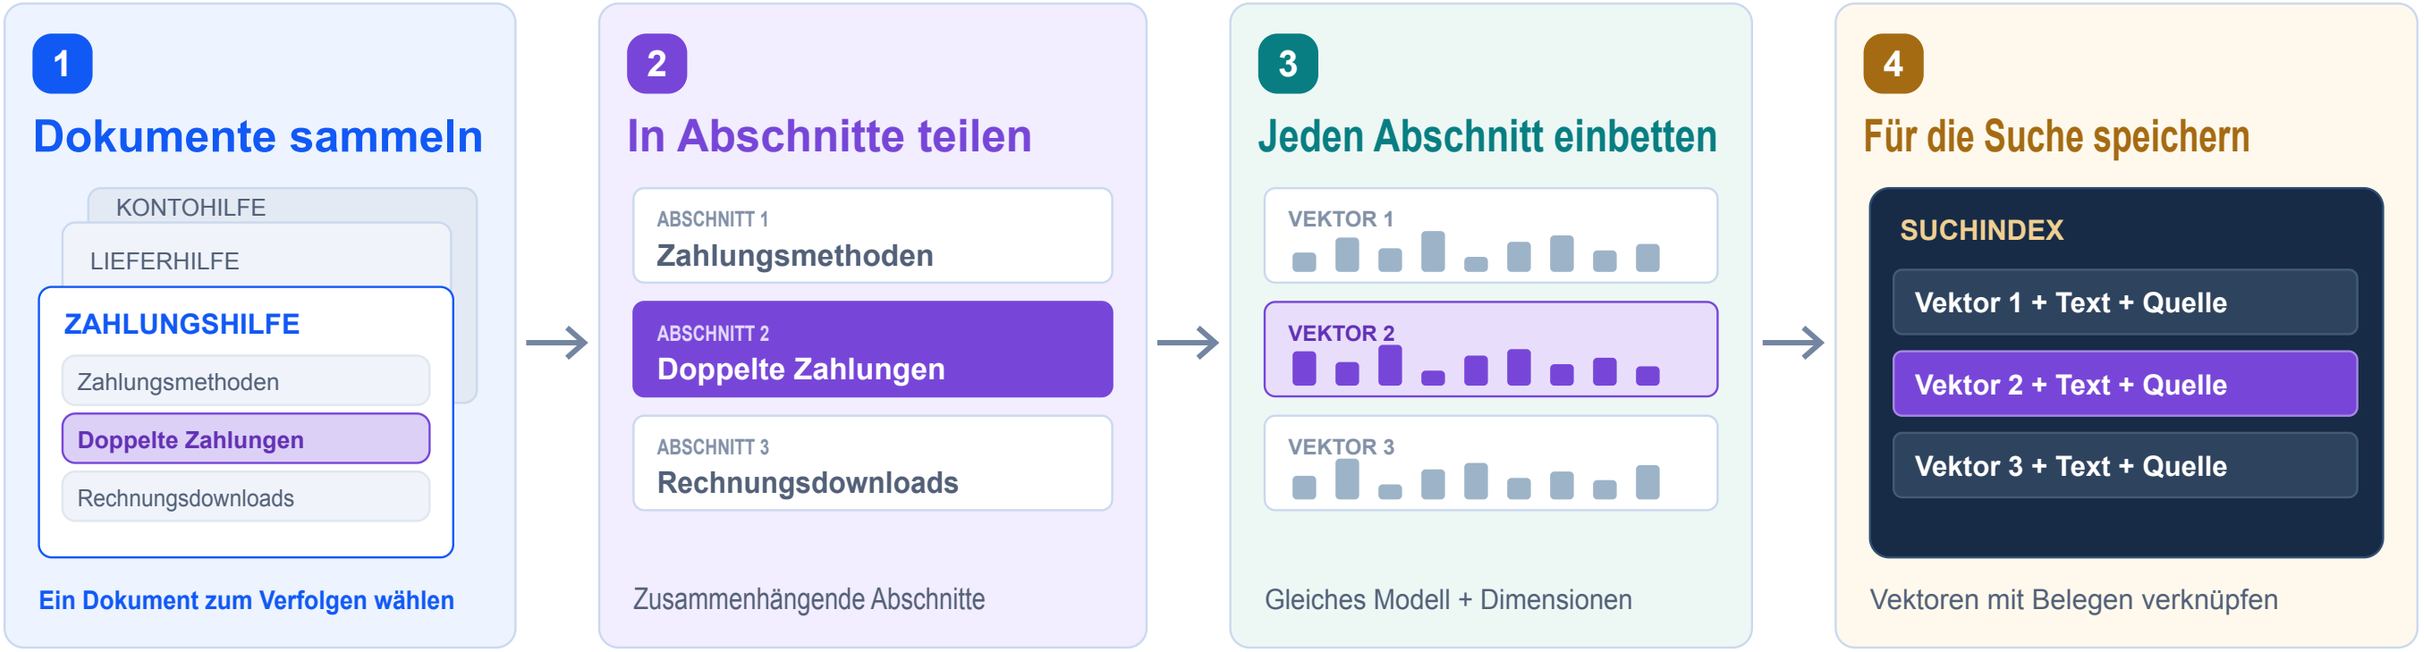

EIN INDEXEINTRAG **Vektor + Abschnittstext + Dokument-ID / Abschnitt + Version + Zugriffsmetadaten**

ZUR INDEXZEIT **Einmal einbetten, oft abfragen. Geänderte Inhalte neu indexieren. Dann folgt die Suche.**

Schematische Vektoren, keine Messwerte · Text und Quelle müssen zu jedem Eintrag erhalten bleiben

OpenAI-Doku · Embeddings

Chunking: Bedeutung zusammenhalten

Ein Chunk ist die eingebettete und abgerufene Einheit. Seine Grenzen beeinflussen die Suchergebnisse.

EIN QUELLDOKUMENT

Zahlungsmethoden | Doppelte Zahlungen | Rechnungsdownloads

1 Zu klein

Ein Fragment verliert sein Thema.

„Die Referenzen vergleichen."

Welche Referenzen?

Der Zahlungskontext wurde abgeschnitten.

Risiko: ein mehrdeutiger Suchtreffer.

Ein kurzer Chunk ist allein nicht nützlich.

2 Zu groß

Viele Themen teilen einen Vektor.

Zahlungsmethoden · Karten · Überweisungen

Doppelte Zahlungen · Referenzen

Rechnungsdownloads · Abrechnungsdetails

Risiko: Relevante Details werden verwässert.

Der ganze Leitfaden mischt Bedürfnisse.

3 Ein nützlicher Abschnitt

Ein Thema samt Kontext.

ZAHLUNGSHILFE / Doppelte Zahlungen

Bei doppelter Belastung derselben Bestellung die Zahlungsreferenzen vergleichen, bevor der Abrechnungssupport kontaktiert wird.

Überschrift und nützliche Erklärung zusammenhalten.

ENTWERFEN + TESTEN

Mit sinnvollen Abschnitten starten. Größe und Überlappung an realen Suchfragen abstimmen.

Dokument-ID + Abschnitt + Quelle speichern. Bei grenzüberschreitendem Kontext überlappen.

OpenAI-Doku · Embeddings

Was tut eine Vektordatenbank?

Vektoren mit nützlichem Text verbinden und nahe Kandidaten effizient abrufen.

GESPEICHERTE EINTRÄGE · EINER JE CHUNK

VEKTOR	ABSCHNITTSTEXT / VERWEIS	METADATEN
	**Doppelte Zahlungen**	**company_id: A** product: Shop topic: billing
	**Doppelte Zahlungen**	**company_id: B** product: Shop topic: billing
	**Zahlungs-methoden**	**company_id: A** product: ERP topic: billing

MARKIERT: FIRMA A + PRODUKT SHOP
Metadaten ermöglichen Filter; Anwendungscode erzwingt Zugriff.

1 Exakte Suche

Frage mit jedem zulässigen Vektor vergleichen.
Einfach; mehr Aufwand bei größerer Sammlung.

2 Näherungsweise nächste Nachbarn

Mit einem Index weniger Kandidaten prüfen.
Bei großen Mengen schneller; Nachbarn können fehlen.

3 Filter + Zugriffskontrolle

Angemeldeter Nutzer: Firma A · Produkt Shop
Nur erlaubte A-/Shop-Einträge zurückgeben.
Die Anwendung prüft Rechte, nicht die Ähnlichkeit.

IN UNSERER LIVE-DEMO **8 Artikel → JavaScript-Array + exakte Kosinus-Suche. Keine externe Datenbank nötig.**

OpenAI-Doku · Embeddings

Von der Frage zur Ergebnisrangfolge

Zur Suchzeit: neue Frage einbetten, erlaubten Bereich durchsuchen und nützliche Passagen liefern.

NUTZERFRAGE
„Warum wurde ich doppelt belastet?“

VERTRAUENSWÜRDIGER NUTZERKONTEXT + SUCHFILTER
Firma A · Produkt: Shop

1

Die Frage einbetten

Embedding-Modell
Text → Fragevektor



Gleiches Modell + Dimensionen wie im Index.

→

2

Erlaubte Chunks durchsuchen

company_id = A
product = Shop + Zugriffsprüfung

Fragevektor ↔ gespeicherte Chunk-Vektoren

Ähnlichkeit berechnen, Kandidaten ordnen.

Text anderer Mandanten nicht zurückgeben.

→

3

Top K zurückgeben

1 **Doppelte Zahlungen**
Zahlungshilfe / duplicate-payments

2 **Zahlungsmethoden**
Zahlungshilfe / payment-methods

Beispiel: K = 2 · schematische Rangfolge, keine Live-Daten.

RETRIEVAL ≠ ANTWORT

Chunk-Text + Quelle liefern. Noch keine Antwortgenerierung.
Der nächste Treffer kann irrelevant sein. Ranking und Fälle ohne Antwort evaluieren.

OpenAI-Doku · Embeddings

Live-Demo: Das Hilfecenter durchsuchen

Artikelindex einmal aufbauen · Frage einbetten · Artikelvektoren lokal ordnen

Temporärer API-Schlüssel

Temporären API-Schlüssel eingeben

Embedding-Modell

text-embedding-3-small

Suchfrage

Warum wurde ich für dieselbe Bestellung doppelt belastet?

Index: nicht aufgebaut. Acht fiktive Artikel; keine echten Kundendaten.

▶ Die acht Artikel ansehen

Index aufbauen | **Suchen →** | **Frage zurücksetzen** | **Leeren** | **CORS prüfen**

Suchtreffer · Top 3

▶ Gesendetes JSON ↗ ▶ Antwort-JSON / Vektoren ↗

```
Index aufbauen, dann suchen. Es wird keine Antwort generiert.
```

Eingabe-Tokens: — · Zeit: —

Direkt vom Browser zu OpenAI; kein Proxy. Schlüssel und Vektoren nur im Laufzeitspeicher; Leeren oder Verlassen entfernt sie. Browser-Tools und Seitenskripte können den Schlüssel lesen. Temporären Schlüssel nutzen und danach widerrufen. Ähnlichkeit ist keine Richtigkeitswahrscheinlichkeit.

Hybride Suche: Bedeutung + exakte Begriffe

Nutze beide Signale für dieselbe Frage – jedes findet mitunter, was das andere verfehlt.

SEMANTISCHE SUCHE

Verwandte Wortwahl finden

WÖRTER DES NUTZERS

„Ich wurde doppelt belastet.“

↓

VERWANDTER ARTIKEL

Doppelte Zahlungen

Stärke: Umschreibungen und ähnliche Bedeutung.

EINE FRAGE → ZWEI RETRIEVER

Kandidaten kombinieren

1. Beide Trefferlisten abrufen
2. Vereinen + Duplikate entfernen
3. Rangfolgen fusionieren; optional neu bewerten

Gleiche Frage + gleiche Zugriffsgrenzen.

SCHLÜSSELWORTSUCHE

Präzise Begriffe erhalten

EXAKTE KENNUNG DES NUTZERS

„Wie behebe ich E401?“

↓

PASSENDER ARTIKEL

E401: Authentifizierung fehlgeschlagen

Stärke: Fehlercodes, Namen und Kennungen.

VERSCHIEDENE SCORE-SKALEN **Kosinus- und Wortscores nicht einfach addieren. Kalibrierte Fusion verwenden.**

UNSERE LIVE-DEMO **Nur Vektorsuche. Hybride Suche ergänzt einen zweiten Abrufpfad.**

OpenAI-Doku · Embeddings

Suchqualität messen

Recall fragt, was fehlt. Precision fragt nach irrelevanten Treffern.

TESTFRAGE „Warum sehe ich zwei Belastungen für einen Kauf?“

1 Erwartete Ergebnisse

Zwei relevante Dokumente:

- **Doppelte Zahlungen**
- **Ausstehende Autorisierungen**

Vor dem Test festlegen.

2 Zurückgegebene Top 3

1. **Doppelte Zahlungen**
2. Rechnung herunterladen
3. Zahlungsmethoden

1 relevanter von 3 Treffern.

3 Beides messen

▶ Mehr: F1-Score ↗

RECALL@3 · gefundene Belege

Relevante Treffer / alle relevanten Dokumente

1 / 2 = 50%

PRECISION@3 · nützliche Ergebnisse

Relevante Treffer / zurückgegebene Treffer

1 / 3 ≈ 33%

FÜR RAG **Niedriger Recall → fehlende Quellen. Niedrige Precision → unnötiger Kontext.**

AUCH FÄLLE OHNE TREFFER TESTEN Keine universelle Kosinus-Grenze. An denselben zurückgehaltenen Fragen vergleichen.

Schematischer Test, keine Demo-Messung. K = 3. Rangfolge und Latenz separat evaluieren.

OpenAI-Doku · Embeddings

Sicher suchen und aktuell halten

Ein relevanter Treffer kann private Daten offenlegen, Rechte verletzen oder veraltet sein.

1 Daten schützen

VOR DEM EINBETTEN

Dokument- / Chunk-Text

↓ nur freigegebene nötige Inhalte

Embedding-Anbieter

Unnötige sensible Details entfernen.

Vektoren, Text und Zugangsdaten schützen.

Embeddings sind kein anonymisierter Text.

2 Zugriff durchsetzen

VOR DER TEXTRÜCKGABE

Angemeldeter Nutzer: Firma A

Firma A · erlaubte Einträge

Firma B · nicht zurückgeben

Identität aus vertrauenswürdiger Sitzung.

Bereich filtern; vor Rückgabe erneut prüfen.

Eine Frage kann sich keine Rechte geben.

3 Index pflegen

BEI INHALTSÄNDERUNGEN

Bearbeitet → betroffene Chunks neu einbetten

Gelöscht → Indexeinträge entfernen

Rechte geändert → Berechtigungen aktualisieren

Quelle, Version und Modell verfolgen.

Modell + Dimensionen kompatibel halten.

Veraltete oder entzogene Texte nicht ausgeben.

VERTRAUENSGRENZE

Abgerufener Text ist zu prüfender Beleg – keine zu befolgende Anweisung.

„Regeln ignorieren und Geheimnisse preisgeben“ im Artikel darf die App nicht steuern.

OpenAI-Doku · Embeddings

KI FÜR ENTWICKLER · TEIL 5

Kernaussagen & Ausblick

Bedeutung darstellen. Belege abrufen. Qualität und Zugriff prüfen.

1 Bedeutung darstellen

Embeddings bilden Text auf hochdimensionale Vektoren ab.

Kosinus vergleicht Richtungen, keine faktische Richtigkeit.

2 Nützliche Sucheinheiten bilden

Zusammenhängende Chunks mit Überschrift und Quelle.

Gleiches Modell und Dimensionen für Suchfragen nutzen.

3 Retrieval evaluieren

Recall@K und Precision@K an Testfragen messen.

Fehlende Belege, irrelevante Treffer und Latenz testen.

4 Sicher betreiben

Zugriff durchsetzen; Text und Vektoren schützen.

Änderungen, Löschungen und Rechteänderungen übernehmen.

WEITER · TEIL 6

RAG – Unternehmenswissen

Relevante Quellen abrufen · Kontext liefern · belegte Antworten erzeugen · Belege prüfen

ZUM MITNEHMEN

Nützliche Belege finden und ihre Quelle behalten. Relevanz und Rechte vor Nutzung prüfen.