

Neuronale Netze verstehen – Dein Lernweg von Null auf Aha

***Das Playbook für Neugierige, die verstehen wollen, wie
KI wirklich denkt***



Dein Gehirn lernt ständig – beim Tee aufgießen, beim Schlendern über einen Markt in Marrakesch. Neuronale Netze tun dasselbe. Dieses Playbook zeigt dir wie – Schritt für Schritt, ohne Vorwissen.



Was du lernst

Die Kernbegriffe neuronaler Netze – klar erklärt, sofort verständlich

Wie wir es angehen

Vom Vertrauten ins Neue – immer mit einem Beispiel aus dem echten Leben

Was du mitnimmst

Echtes Verstehen statt bloßes Merken – ein Gefühl für KI, das bleibt



powered by AI: Recherche, Iteration, Kuration & Redaktion: Carmen Frohne | September 2026



Wie dieses Playbook aufgebaut ist

Stell dir eine Wanderung durch sechs Etappen vor. Jede Etappe hat ihren eigenen Charakter – der Weg führt dich logisch von einem zum nächsten. Du brauchst keine Ausrüstung. Nur Neugier und gute Schuhe. 🥾



Das Neuron verstehen

Du lernst, wie ein einzelnes Neuron aufgebaut ist – der Schlüssel zu allem.



Das Netzwerk aufbauen

Aus einem Neuron wird ein Netzwerk – das Ganze ist mehr als die Summe seiner Teile.



Vektoren & Daten

Wie Informationen als Zahlen kodiert werden – die Sprache, die KI versteht.



Wie eine KI lernt

Wir beobachten, wie sich Gewichte verschieben und das Netz sich anpasst.



Gesellschaftlicher Bias & moderne KI


Woher Vorurteile in KI-Systemen kommen – und warum das uns alle betrifft.



Deine eigene KI bauen

Wir sehen, wo neuronale Netze heute wirken – und wie du selbst loslegen kannst.

Jedes Kapitel startet mit einer Alltagsszene, zoomt dann rein – und endet mit einem kurzen **Workbook-Moment** zum Innehalten und Verankern. 📝



Die Wurzeln: Was ist ein neuronales Netz?

Ein künstliches neuronales Netz ist ein Computerprogramm – grob dem Gehirn nachempfunden. Es arbeitet *nicht* mit „Wenn-Dann“-Regeln, die ein Mensch eingetippt hat. Es lernt selbstständig, Muster zu erkennen. Zum Beispiel: Hund oder Katze auf einem Foto?

Dieses Prinzip kennst du aus eigener Erfahrung. Jedes Mal, wenn du etwas gelernt hast – ohne dass jemand dir eine Regel erklärt hat – war das dein persönliches neuronales Netz.

Ein neuronales Netz lernt aus Beispielen – genau wie wir. Kein Regelwerk. Keine Wenn-Dann-Ketten. Nur Muster, Erfahrung und Anpassung.

Unsere Roadmap – der ganze Weg auf einen Blick

Bevor wir starten, schauen wir kurz auf die Karte. Was liegt vor uns? Diese Übersicht zeigt dir jederzeit, wo wir sind und wohin wir gehen.

01	02	03
Kapitel 1: Das einzelne Neuron	Kapitel 2: Das Netzwerk	Kapitel 3: Vektoren & Daten
Features, Gewichte, Bias – das Innenleben einer einzigen Entscheidung	Input, Hidden, Output Layer – die Schichten der Informationsreise	Vektoren, One-Hot-Encoding, GIGO – die Sprache der KI
04	05	06
Kapitel 4: Wie eine KI lernt	Kapitel 5: Gesellschaftliche r Bias & moderne KI	Kapitel 6–8: Deine eigene KI, Deep Learning & Ausblick
Forward Pass, Loss Function, Backpropagation – so wird eine KI klüger	Bias, RAG, LoRA, Context Window – so setzt man echte KIs heute ein	Gemeinsam bauen wir eine eigene KI – als lebendiger Abschluss und Blick in die Zukunft

Das einzelne Neuron – Eine Entscheidung, ganz nah betrachtet

☀️ **Lagos, 7:15 Uhr morgens.** Amara schiebt die Markise zurück und schaut in den Himmel. Grau – aber nicht dunkel. Die Wetter-App zeigt: 60 % Regenwahrscheinlichkeit. Ihre Nachbarin läuft gerade vorbei – mit Schirm. *Nehme ich meinen Schirm mit?*

Amara denkt nicht über Logik nach. Trotzdem verarbeitet ihr Gehirn gerade mehrere **Informationen gleichzeitig**:

☁️ Himmelsfarbe

Grau – aber nicht bedrohlich. **Schwaches Signal.**

📱 Wetter-App

60 % Regen. **Mittleres Signal.**


👤 Nachbarin

Hat Schirm dabei. **Starkes Signal.**

Diese Informationen heißen in der KI-Welt **Features** oder **Inputs** – das, was in eine Entscheidung hineinfließt. Nicht alle zählen gleich viel. Die Nachbarin mit Schirm überzeugt Amara mehr als der graue Himmel. Manche Signale **wiegen mehr** als andere.

Genau das tut ein künstliches **Neuron**: Es empfängt mehrere Inputs, bewertet jeden nach seiner Wichtigkeit – und gibt ein klares Ergebnis aus. *Schirm: ja oder nein.*

📌 **Merke:** Ein Neuron ist eine winzige Entscheidungsmaschine. Es nimmt Zahlen herein, gewichtet sie – und gibt eine Antwort.



Ein Neuron empfängt Inputs (Features), bewertet sie mit **Gewichten** und gibt einen **Output** aus.

Input / Feature


Eine einzelne Information, die reinkommt

Gewicht (Weight)

Wie wichtig ist dieser Input?

Output

Die finale Entscheidung des Neurons



Was ist ein Feature?

Ein **Feature** ist eine messbare Eigenschaft unserer Umwelt – ein Informationshäppchen, das wir beobachten können.

Feature 1

Ist der Himmel dunkel?

Messbar als: Ja (1) oder Nein
(0)

Feature 2

Meldet die Wetter-App Regen?

Messbar als: Prozentsatz, z. B.
80 %

Ein Feature lässt sich immer in eine Zahl übersetzen. Computer verstehen nur Zahlen – keine Bilder, keine Worte, keine Gefühle. Erst Zahlen ermöglichen einer KI das Arbeiten.

 „Feature“ kommt aus dem Englischen und bedeutet „Merkmal“. In der KI-Welt verwenden wir beide Begriffe gleichwertig.

Das Neuron – der kleine Entscheidungsträger

Jetzt kommen die Features zusammen. Du entscheidest. In einem künstlichen neuronalen Netz übernimmt diese Rolle ein **Neuron** – auch **Node** oder **Knotenpunkt** genannt.



Im menschlichen Gehirn

Neuronen nehmen Signale auf, verknüpfen sie und senden ein Ergebnis weiter – je nach Signalstärke.



Im künstlichen Netz


Das künstliche Neuron nimmt Zahlen (Features) auf, rechnet damit und gibt ein Ergebnis aus – zum Beispiel: „Schirm: Ja“.

Das Neuron ist ein winziger Entscheidungsträger. Es nimmt Features auf, gewichtet sie und fällt ein Urteil. Wie es gewichtet? Das erklärt der nächste Begriff.

Gewichte – die Relevanz einer Information

Schau dir die beiden Features an: „dunkler Himmel“ und „Wetter-App“. Sind beide gleich wichtig? Wahrscheinlich nicht. Die Wetter-App ist zuverlässiger. Der Himmel kann sich schnell verändern.

Das ist das Prinzip der **Gewichte** (*Weights*). Jedes Feature erhält einen Gewichtswert. Dieser bestimmt, wie stark das Feature die Entscheidung des Neurons beeinflusst.



Gewichtung = Relevanz. Ein hoher Gewichtswert bedeutet: Diese Information zählt stark bei der Entscheidung.

Bias – die innere Grundtendenz

Stell dir vor: Du hasst nasse Schuhe und bist grundsätzlich vorsichtig. Selbst wenn der Himmel hell ist und die App kaum Regen anzeigt – du packst den Schirm ein. Du hast eine Grundstimmung, die deine Entscheidung in eine Richtung zieht. Noch bevor du die Fakten abwägst.

Der **Bias** ist ein inneres Vorurteil: „Egal was Himmel oder App sagen – ich bin heute vorsichtig und tendiere zum Schirm.“



Gewicht (Weight)

Regelt, wie relevant ein Feature für die Entscheidung ist. Bezieht sich immer auf einen konkreten Eingang.



Bias


Verschiebt die Grundtendenz – unabhängig von den Features. Er wirkt immer, egal was die Eingangsdaten sagen.

Gewicht und Bias arbeiten zusammen, sind aber nicht dasselbe. Gewicht = Relevanz eines Features. Bias = Grundtendenz aus Erfahrung. Zusammen bestimmen sie das gesamte Verhalten eines Neurons.

Woher kommt der Bias? – Der Würfelwurf zu Beginn


Bei Menschen entsteht die Grundstimmung durch Erfahrung. Bist du mal ohne Schirm nass geworden, steigt dein Bias für den Schirm danach automatisch. Aber wie ist das bei einer frisch erstellten KI?

In einem neuen neuronalen Netz ist der Start einfach: Bias und Gewichte beginnen als **zufällige Zahlen**. Das Netz rät zu Beginn blind. Es ist ein völlig unbeschriebenes Blatt.



Das Innenleben eines Neurons – Zusammenfassung

Wir haben alle wichtigen Zutaten eines Neurons beisammen. Lass uns alles in einem Bild zusammenbringen.



Features aufnehmen, gewichten, Bias hinzufügen, Ergebnis ausgeben – das ist das Herzstück. Alles in den nächsten Kapiteln baut auf diesen Wurzeln auf. Das einzelne Neuron ist der kleinste Baustein des ganzen Systems.



Workbook-Moment: Dein eigenes Neuron

Jetzt bist du dran. Dieses Neuron kennt dich noch nicht – füttere es mit mir. Beantworte die folgenden Fragen für dich. Direkt hier oder im Notizbuch.



Reflexionsfrage 1

Welche zwei oder drei Features nutzt du bei einer alltäglichen Entscheidung? Zum Beispiel: Soll ich heute früh aufstehen?



Reflexionsfrage 2

Welches Feature hat das höchste Gewicht – die größte Relevanz? Und warum?



Reflexionsfrage 3

Gibt es eine Grundtendenz (Bias), die bei dieser Entscheidung immer mitschwingt – unabhängig von den Fakten?




Es gibt keine richtigen oder falschen Antworten. Dieser Moment verankert das Gelernte tiefer als jede Wiederholung.

Das Netzwerk – Wenn viele Neuronen zusammenarbeiten

Hidden Layer

Stell dir ein Team in einem Tokioter Büro vor. Das Projekt: Sollen sie heute noch ein Kundentreffen einberufen? Drei Rollen, eine Entscheidung.



Drei Schichten, ein Gedanke – so denkt ein neuronales Netz.

Die Empfangsdame – Input Layer

Sie nimmt alle Infos entgegen: Wie voll ist der Kalender? Wie weit ist der Kunde? Wie dringend ist das Anliegen? Das **Input Layer** empfängt die rohen Daten und gibt sie weiter. Kein Filtern, kein Bewerten.

Die Analysten im Hinterraum – Hidden Layers

Drei Kollegen sitzen im Nebenraum und diskutieren. Sie gewichten, kombinieren, schätzen Risiken ein – unsichtbar für alle anderen. Die **Hidden Layers** sind das Herzstück des Netzwerks. Hier denkt das Netz – Schicht für Schicht, wie Jahresringe eines Baumes.

Die Teamleiterin – Output Layer

Sie tritt heraus und verkündet: „Wir treffen uns heute um 16 Uhr.“ Das **Output Layer** ist die finale Stimme des Netzwerks – es liefert die Entscheidung, die wir sehen und nutzen.

- ☐ Ein einzelnes Neuron ist noch keine KI. Die Magie entsteht, wenn **viele Neuronen in Schichten** zusammenarbeiten – jede Schicht versteht die Welt besser als die vorherige.

Die drei Schichten – Ein Überblick



Input Layer

Die Warenannahme.

Hier kommen die
rohen Daten an.

Jede Spalte deiner
Datentabelle
entspricht einem
Knoten in dieser
Schicht.



Hidden Layer(s)

Die Denkräume. Hier
denkt das Netz.

Jedes Neuron
kombiniert
eingehende Signale
und bildet
abstraktere
Konzepte.



Output Layer

Das Ergebnis. Hier
liefert das Netz
seine Antwort – zum
Beispiel eine
Wahrscheinlichkeit
für jeden möglichen
Ausgang.

Das Output Layer ist *nicht* das Lösungsheft. Es ist die Antwort der KI – wie die Lösung, die ein Schüler auf sein Prüfungsblatt schreibt. Das echte Lösungsheft liegt daneben und kommt erst danach zum Vergleich.

Warum heißen sie „Hidden“ Layers?

Der Name ist pragmatisch entstanden – nichts Geheimnisvolles. Es geht darum, welche Schichten Kontakt zur Außenwelt haben – und welche nicht.

Sichtbar von außen 👁

Das **Input Layer** sieht deine Rohdaten – direkter Kontakt zur Außenwelt.

Das **Output Layer** gibt seine Antwort nach außen – auch es hat direkten Kontakt.


Im Inneren verborgen 🧐

Alles dazwischen hat **keinen direkten Kontakt** zur Außenwelt – weder zu den Rohdaten noch zum Endergebnis. Es liegt verborgen (*hidden*).

Das macht diese Schichten für uns schwer lesbar – daher auch der Begriff **Blackbox**.

Was die Hidden Layers wirklich tun – Vom Pixel zum Hund

Stell dir ein neuronales Netz vor, das auf einem Foto einen Hund erkennt. Das Input Layer liefert tausende winzige Bildpunkte. In den Hidden Layers erwacht schrittweise die Bedeutung.



Das ist das Herzstück des **Deep Learning**. Mehr Hidden Layers bedeuten: Das Netz lernt tiefere, abstraktere Konzepte.

Die Schüler-Analogie – Prüfung, Lösungsheft, Fehler

Ein neuronales Netz funktioniert wie ein Schüler in der Prüfung. Dieses Bild macht die Rollen der einzelnen Schichten klar.



Input Layer – Die Prüfungsaufgabe

Der Schüler liest die Aufgabe. Das Input Layer nimmt die rohen Daten entgegen.



Hidden Layers – Das Denken

Der Schüler grübelt, kombiniert, erinnert sich. Die Hidden Layers verarbeiten die Information.



Output Layer – Die Antwort

Der Schüler schreibt seine Antwort auf. Das Output Layer gibt die Vorhersage aus.



Lösungsheft – Die Realität

Das Lösungsheft liegt neben dem Netz. Es enthält die echte Wahrheit – und gehört nicht zum Netz selbst.



Workbook-Moment: Schichten erkunden

Nimm eine Entscheidung aus deinem Alltag - zum Beispiel: „Soll ich heute ins Fitnessstudio gehen?“ Übertrage sie in die drei Schichten.

1

Input Layer

Welche konkreten Informationen gibst du ein? Habe ich gut geschlafen? Habe ich Zeit? Bin ich motiviert?

2

Hidden Layer

Was passiert in deinem Kopf? Wie verknüpfst du die Informationen? Welches Gefühl entsteht daraus?

3

Output Layer

Was ist deine finale Antwort - und wie sicher bist du? Zum Beispiel: „Ich gehe zu 70 % ja.“

Vektoren – Das Datenpaket an der Warenannahme

Elena steht in ihrer Küche in Oaxaca. Sie schreibt ihr Mole-Rezept auf – nicht als Fließtext, sondern als Liste:

 **Chilis**

3 Stück

 **Kakao**

2 Löffel

 **Knoblauch**

4 Zehen

 **Öl**

1 Schuss

Dann ersetzt sie die Mengen durch Zahlen: [3, 2, 4, 1]. Das ist ein **Vektor**.

Ein **Vektor** ist eine **geordnete Liste von Zahlen** – das Datenpaket für ein einziges Beispiel. Jede Zahl steht für ein **Feature**. Die Reihenfolge zählt immer.

Dem Computer ist egal, ob es um Mole, Wohnungspreise oder Herzraten geht. Er sieht immer dasselbe: eine Zahlenreihe. Das ist **Vektoren in Aktion**.


Feature

Ein messbares Merkmal eines Beispiels

Vektor

Die geordnete Liste aller Features als Zahlen

 **Merke:** Jede Zeile in deiner Datentabelle = ein Vektor = ein Beispiel für das Netz.



h 4

Ein Vektor in Aktion – Das Regenschirm-Beispiel

Zurück zu unserem Morgen an der Tür. Feature 1 (Himmel dunkel): Wert 1.
Feature 2 (Wetter-App sagt 80 % Regen): Wert 0,8. Der Vektor sieht so aus:

Feature 1	Feature 2	Input-Vektor
Himmel dunkel? Wert: 1	Wetter-App: 80 % Wert: 0,8	Das komplette Paket: [1 ; 0,8]

Der Input-Vektor ist das rohe Datenpaket. Das Netz gibt es am Eingang – dem Input Layer – ab. Bis dahin hat das Netz noch nichts berechnet. Gewichte und Bias kommen erst danach – im Inneren der Schichten.

One-Hot-Encoding – Wenn Ja und Nein zu Zahlen werden

Manche Features sind keine Zahlen – sondern Kategorien. Warm oder kalt. Fingerfood oder Suppe. Mittags oder abends. Der Computer versteht nur Zahlen. Also übersetzen wir.

Diese Übersetzung heißt **One-Hot-Encoding**. Jede Kategorie bekommt eine eigene Spalte. Die aktive Option erhält eine **1**, alle anderen eine **0**.

Merkmal	Warm	Kalt	Finger food	Suppe	Mittags	Abends
Warme Abendsuppe	1	0	0	1	0	1
Kaltes Mittags-Finger food	0	1	1	0	1	0

Jede Zeile ist ein Input-Vektor für genau einen Moment. Der Computer sieht nur die Zahlen. Die Spaltenüberschriften sind für uns – damit wir den Überblick behalten.

Vektor für ein Auto – Praktisch üben

Wir bauen eine KI, die den Verkaufspreis eines Gebrauchtwagens schätzt. Drei Features: Alter in Jahren, Kilometerstand und PS-Zahl.



Das konkrete Auto

Alter: 5 Jahre

Kilometerstand: 10.000 km

PS: 75 PS



Der Input-Vektor

Das Datenpaket für dieses Auto:

[5 ; 10000 ; 75]

Drei Zahlen. Sortiert. Fertig.

Das ist alles. Kein Gewicht, kein Bias – das kommt erst in den Schichten. Der Vektor ist das rohe Datenpaket. Danach beginnt die KI zu rechnen.

Garbage In, Garbage Out – Datenpflege ist alles

Was passiert, wenn die Daten im Vektor fehlerhaft sind? Zum Beispiel: Jemand setzt bei einer Person gleichzeitig „unter 18“, „18-25“ und „26-50“ auf 1.

Das Input Layer streikt nicht und meldet keinen Fehler. Es ist wie eine Laderampe: Es nimmt die Zahlen an – ohne den Sinn zu prüfen. Das Netz sieht nur Zahlen und schickt sie weiter. Die Hidden Layers rechnen stur drauflos.

In der Informatik heißt das Prinzip: **Garbage In, Garbage Out** 🗑️ – Müll rein, Müll raus. Fehlerhafte Eingabedaten erzeugen unsinnige Vorhersagen.

Deshalb verbringen KI-Entwickler*innen oft **80 % ihrer Arbeitszeit** mit Datenvorbereitung und Data Cleaning – bevor das Netz überhaupt trainiert wird. Saubere Daten sind die Wurzel von allem.



Workbook-Moment: Dein eigener Vektor

Wähle eine Alltagsentscheidung - zum Beispiel: Buch lesen oder Film schauen?
- und übersetze sie in einen Input-Vektor.

Schritt 1: Features benennen

Welche 2-4
Merkmale
beeinflussen deine
Entscheidung?

Schritt 2: In Zahlen übersetzen

Übersetze jedes
Feature in eine
Zahl - Ja/Nein
(1/0) oder ein
Prozentwert.

Schritt 3: Vektor aufschreiben

Schreibe deine
Zahlen in eckigen
Klammern: [Zahl1 ;
Zahl2 ; Zahl3].


Wie eine KI lernt – Der Lernkreislauf

Arjun ist zwölf Jahre alt und wohnt in Pune, Indien. Er lernt Fahrrad fahren. Er steigt auf. Er fährt los. Er fällt. Er steht wieder auf. Sein Gehirn registriert: *Zu weit nach links gelehnt.* Nächster Versuch: etwas besser. Genau so lernt eine KI.

1. Forward Pass

Schritt 1: Forward Pass – Der erste Versuch

Die KI erhält Daten – zum Beispiel ein Bild einer Katze. Sie schickt sie durch alle Schichten des Netzes. Am Ende kommt eine Antwort: „Das ist ein Hund.“ Falsch! Aber der Versuch ist gemacht.



 Der Lernkreislauf einer KI – vier Schritte, unendlich oft wiederholt

Forward Pass

Daten durch das Netz schicken → Antwort erzeugen

Loss messen

Fehler berechnen → wie weit lag die KI daneben?

Backprop

Rückwärts fragen → wer hat den Fehler verursacht?

Anpassen

Gewichte korrigieren → beim nächsten Mal besser

 Intelligenz entsteht durch geduldiges Wiederholen und Korrigieren – tausende Male.

Schritt 2: Loss Function – Den Fehler messen

Die KI misst, wie falsch sie lag. Diese Messung heißt **Loss** – auf Deutsch: Verlust. Je größer der Loss, desto weiter daneben. Wie Arjuns Sturz: Der Körper spürt genau, wie schief es lief.

Schritt 3: Backpropagation – Rückwärts lernen

Die Information läuft rückwärts durch das Netz. Die KI fragt bei jeder Schicht: *Welches Gewicht hat den Fehler verursacht?* Diese Technik heißt **Backpropagation** – kurz: Backprop. Arjuns Gehirn macht dasselbe: Es prüft, welcher Muskel zu wenig reagiert hat.


Schritt 4: Gewichte anpassen – Besser werden

Die Gewichte im Netz ändern sich minimal. Nicht zu viel – sonst lernt die KI chaotisch. Nicht zu wenig – sonst lernt sie gar nichts. Dieser Schritt heißt **Gradient Descent**. Arjun lehnt sich beim nächsten Versuch ein bisschen mehr nach rechts.

3. Backprop

Forward Pass – Das Wasser fließt vorwärts

Beim **Forward Pass** fließen die Daten von vorne nach hinten – vom Input Layer durch alle Hidden Layers bis zum Output Layer. Das Netz verrechnet die Features mit den aktuellen Gewichten und gibt seine Schätzung aus.



Das Netz rät hier noch. Es hat dieses Beispiel vielleicht nie gesehen. Sein Output ist der beste Versuch auf Basis aller bisher gelernten Gewichte. Ob dieser Versuch gut oder schlecht war, zeigt der nächste Schritt.

Die Loss Function – Der Qualitätsprüfer am Ausgang

Das Netz hat seine Vorhersage gemacht. Jetzt tritt die **Loss Function** (Verlustfunktion) auf den Plan. Sie misst den Abstand zwischen Vorhersage und Realität.



Was das Netz sagt

Das Auto kostet: **15.000 €**
(Vorhersage des Output Layers)



Was die Realität sagt

Das Auto wurde verkauft für: **10.000 €**
(Der echte Wert aus dem Lösungsheft)

Die Loss Function stellt fest: „Der Fehler beträgt 5.000 €.“ Diese Zahl startet das Lernen. Ohne sie weiß das Netz nicht, wie weit es daneben lag – und wohin es sich korrigieren soll.

Backpropagation – Das Wasser schwappt zurück

Jetzt startet der zweite Takt: die **Backpropagation** (Rückwärtsverbreitung). Der Qualitätsprüfer nimmt den Fehlerwert und schickt ihn rückwärts durch alle Schichten.


Er geht von hinten nach vorne zu jedem Neuron und sagt: „Du hattest das Gewicht für die PS-Zahl zu hoch – das hat zur Überschätzung beigetragen. Schraub es zurück.“ Jedes Neuron passt seine Gewichte und seinen Bias ein kleines Stück an.



Vorwärts raten, rückwärts korrigieren – das wiederholt sich tausende Male. Mit jedem Zyklus nähert sich die Vorhersage der Realität. Die Fehlerkurve sinkt.

Die Lernkurve – Der Fortschritt wird sichtbar

Stellen wir den Fehler des Netzes über die Zeit in einem Diagramm dar, entsteht die **Lernkurve**. Am Anfang – wenn die Gewichte noch zufällige Startwerte tragen – ist der Fehler riesig. Mit jeder weiteren Runde sinkt er.



Die Lernkurve geht nach unten – ein gutes Zeichen. Zuerst lernt das Netz schnell: Die Fehler sind groß, die Korrekturen deutlich. Später verlangsamt sich das Lernen. Die Feinabstimmung braucht mehr Zeit. Irgendwann flacht die Kurve ab. Das Netz hat sein Potenzial ausgeschöpft.

Das Meta-Beispiel – Lernkurve im echten Leben

Du kennst vermutlich die **Learning Phase** bei Werbekampagnen. Innerhalb von sieben Tagen mussten 50 Conversions erreicht werden – sonst blieb der Algorithmus instabil.



Input-Vektor

Ein einzelner Facebook-User mit seinen Features: Alter, bisherige Klicks, Interessen, Wohnort



Output Layer

Vorhersage des Netzes: „Klickt diese Person auf die Anzeige und kauft?“



Die 50 Conversions

Das echte Lösungsheft der Realität – die Daten, mit denen das Netz seine Vorhersagen vergleicht



Lernkurve

Nach ~50 echten Treffern sind die Gewichte stabil genug für präzise Vorhersagen

Was du damals als „Learning Phase“ erlebt hast, war die Lernkurve eines neuronalen Netzes – in Echtzeit, vor deinen Augen. Die KI brauchte diese echten Beispiele, um ihre Gewichte anzupassen.

Die zwei Phasen im Leben einer KI

Ein neuronales Netz durchläuft immer zwei getrennte Phasen. Diese Unterscheidung ist entscheidend, um eine fertige KI zu verstehen und einzusetzen.

Phase 1: **Trainingsphase (Die Schule)**

Wir füttern das Netz mit Millionen alter Daten – und kennen das Lösungsheft bereits. Das Netz rät, vergleicht, macht Fehler und passt Gewichte und Bias an.

Das Wasser fließt vorwärts *und* rückwärts. Dieser Prozess dauert oft Wochen und braucht riesige Computer.

Phase 2: **Anwendungsphase (Der Job)**

Irgendwann macht das Netz kaum noch Fehler. Dann frieren wir die Gewichte und den Bias **ein**. Ab diesem Moment lernt das Netz nichts mehr.

Das Wasser fließt nur noch vorwärts (Forward Pass). Keine Backpropagation. Die Antworten kommen blitzschnell.

Das große Ziel – Vorhersagen für unbekannte Situationen

Das trainierte Netz ist jetzt in einer App auf deinem Handy. Du gibst ihm die aktuellen Daten. Was passiert?

Das Netz nutzt gelernte Muster aus der Vergangenheit, um **Vorhersagen für neue, unbekannte Situationen** zu treffen. Das ist der Sinn des Ganzen.

Es hat Millionen Fälle gesehen. Es hat gelernt, welche Muster zu welchen Ergebnissen führen. Kommt ein neues Beispiel, gibt die KI ihre beste Schätzung ab. Keine Magie. Mustererkennung aus Erfahrung.



Workbook-Moment: Den Lernzyklus in Worte fassen

Beschreibe den Lernzyklus einer KI in eigenen Worten – ohne Fachbegriffe. Erkläre ihn jemandem, der noch nie von KI gehört hat. Das festigt das Verständnis.



Meine Erklärung des Lernzyklus

Was passiert Schritt für Schritt? Was fließt wohin? Was passt sich an?



Meine Analogie dazu


Welches Bild aus deinem Alltag trifft es am besten? Eine Schulprüfung? Kochen lernen? Ein Instrument üben?

Gesellschaftlicher Bias – Wenn KI die Vergangenheit auswendig lernt

Bisher haben wir Bias als mathematischen Wert im Neuron kennengelernt – eine Grundtendenz, die durch Training entsteht. Aber es gibt einen zweiten, gesellschaftlich relevanten Bedeutungsrahmen. Den dürfen wir nicht übergehen.

Was passiert, wenn die Trainingsdaten selbst voller Ungleichheiten stecken? Stell dir vor: Wir trainieren ein Netz mit historischen Personalakten. Darin wurden fast immer Männer befördert.

Wie Vorurteile in KI-Systeme gelangen



Das Netz lernt die Muster aus den Trainingsdaten – auch wenn diese Muster unfair sind. Es erhöht das Gewicht für das Merkmal „männlich“, weil in den historischen Daten hauptsächlich Männer erfolgreich waren. Danach wendet es dieses Muster blind auf neue Bewerber*innen an.

⚠ War die Vergangenheit unfair, lernt die KI diese Unfairness. Sie reproduziert keine böse Absicht – sie reproduziert, was in den Daten steckte. Deshalb ist bewusste Datenpflege (Data Curation) eine ethische Pflicht.

Data Curation – Bewusste Datenpflege als ethische Verantwortung

Die Lösung liegt in der gezielten Auswahl der Trainingsdaten – das nennt man **Data Curation**. Wer die Daten zusammenstellt, formt das spätere Verhalten der KI.



Beispiel: Faire Personalentscheidungen

Waren die historischen Daten unfair, musst du die Trainingsdaten ausbalancieren. Stelle sicher, dass gleich viele erfolgreiche Frauen und Männer darin vorkommen.



Beispiel: Markenstimme und Stil

Willst du, dass eine KI warmherzig und echt schreibt? Dann trainiere sie mit hunderten Texten, die genau diesen Ton tragen.

Wir steuern den Output und den Bias einer KI durch die Auswahl der Trainingsdaten. Das ist einer der wichtigsten Hebel, die wir als Menschen haben.

Die zwei Bedeutungen von Bias – klar unterschieden

Zwei Bedeutungsebenen, sauber getrennt:



Mathematischer Bias

Ein Wert im Inneren eines Neurons. Er startet als Zufallszahl. Das Training passt ihn an. Er wirkt unabhängig von den Eingabedaten als Grundtendenz des Neurons.



Gesellschaftlicher Daten-Bias

Vorurteile und Ungleichheiten, die in historischen Daten stecken. Das Netz lernt sie – und wendet sie auf neue Situationen an. Sie entstehen durch unkritische Datenpflege.

Die Verbindung entsteht, wenn das Netz zu lernen beginnt. Der mathematische Bias ist das Werkzeug. Die gesellschaftlichen Daten sind das Material. Wer das Material bewusst wählt, bestimmt das Ergebnis.

Context Window, RAG und LoRA – Wie moderne KIs wirklich funktionieren

Stell dir **Amina** vor – eine weise Beraterin. Jeden Morgen bringt sie drei Dinge mit:

→ **Ihr Notizbuch**

Was hat die Person heute erzählt? Was besprachen sie letzten Monat? Das ist ihr **Kurzzeitgedächtnis** – frisch, sitzungsbezogen.



Amina – Notizbuch, Fachbuch, Ausbildung. Drei Werkzeuge, ein Ziel.

→ **Ihr Fachbuch**

Bei Unklarheiten schlägt sie nach. Das Wissen kommt **von außen, bei Bedarf** – nicht alles sitzt im Kopf.

→ **Ihre Ausbildung**

Was sie jahrelang lernte, sitzt tief. Es lässt sich nicht täglich neu schreiben – aber **gezielt verfeinern**.

Genau so arbeiten moderne KI-Systeme. Die drei Konzepte haben sogar Namen:

Context Window


= Notizbuch. Alles im aktuellen Gespräch.

RAG

= Fachbuch. Externes Wissen, live abgerufen.

LoRA

= Nachschulung. Gezieltes Feintraining.



RAG – Nachschlagen

Das Context Window – Das Kurzzeitgedächtnis der KI

Wenn du einer KI eine Nachricht schickst, passiert etwas Überraschendes: Der *komplette bisherige Chatverlauf* wird heimlich mitgeschickt. Nicht nur dein letzter Satz – alles. Das Netz empfängt das als einen riesigen Input-Vektor.

 Deine neue Nachricht Was du gerade tippst	 Kompletter Chatverlauf Alles Bisherige – heimlich mitgeschickt
 Input Layer Empfängt das gesamte Paket als riesigen Vektor	 Das Limit Irgendwann ist das Paket voll – ältere Inhalte fallen heraus

Das Context Window hat ein festes Limit. Wächst das Gespräch über tausende Seiten, fallen die ältesten Nachrichten heraus. Das Netz „vergisst“ sie – sie passen schlicht nicht mehr in das Input Layer.

RAG – Die Handtasche mit dem Handbuch

RAG steht für *Retrieval-Augmented Generation* – auf Deutsch: Antworten generieren mit Nachschlagen. Das passende Bild: Eine weise Beraterin, die kurz vor dem Gespräch gezielt im Handbuch nachschlägt.

Wie RAG funktioniert

Die Gewichte der KI bleiben eingefroren. Wenn du eine Frage stellst, durchsucht ein Hilfsprogramm eine externe Datenbank – zum Beispiel alle Firmen-PDFs. Es kopiert die passenden Absätze und klebt sie unsichtbar in deinen Prompt. Die KI liest nach. Sie lernt dabei nichts Neues.

Wann RAG ideal ist

Für Daten, die sich täglich ändern – Aktienkurse, Firmendokumente, Wissensdatenbanken. Kein Nachtraining nötig. Schnell, flexibel, effizient.

LoRA – Die Ventile werden wieder aufgetaut

LoRA steht für *Low-Rank Adaptation*. Hier passiert etwas grundlegend anderes als bei RAG: Ein Teil der eingefrorenen Gewichte taut wieder auf. Eine neue, kleine Trainingsphase beginnt. Das Wasser schwappt vor und zurück (Backpropagation). Das Netz macht Fehler, passt die aufgetauten Gewichte an und lernt ein neues Muster.

Danach frieren die Gewichte wieder ein. Das Netz trägt dieses Muster nun dauerhaft – es ist ein Teil seiner Persönlichkeit geworden.


Anwendungsfall: Markenstimme

Du fütterst das Training mit hunderten Texten im gewünschten Stil. Das Netz lernt diesen Ton dauerhaft – nicht durch Nachschlagen, sondern durch Verinnerlichen.

Nicht für Echtzeit-Daten geeignet

LoRA kostet Zeit und Rechenpower. Für minütlich wechselnde Aktienkurse ist es zu aufwendig – da ist RAG die bessere Wahl.

RAG vs. LoRA – Ein klarer Vergleich



Die Wahl zwischen RAG und LoRA folgt einer Frage: Soll die KI etwas *nachschlagen* oder etwas *dauerhaft verinnerlichen*? Fakten ändern sich – Stil bleibt stabil.

Das eingefrorene Wissen trifft frische Fakten

Basiswissen und aktuelle Fakten arbeiten zusammen – zum Beispiel bei einer Börsenkrise, die es so noch nie gab.



Tiefe Schichten (Basiswissen)

Das eingefrorene Wissen aus dem Training: Wie funktioniert Wirtschaft? Was passiert bei Krisen? Welche Muster gibt es? Dieses Wissen – wie die Jahresringe eines alten Baumes – hilft beim Einordnen neuer Situationen.



Input-Vektor (Neue Fakten)

Aktuelle Fakten, die per RAG eintreffen: „Aktie X ist um 50 % gefallen, weil ein neues Gesetz verabschiedet wurde.“ Diese Fakten füllen die Lücken, die das Training nicht kannte.

Das Output Layer vereint beides: tiefes Musterverständnis aus dem Training und aktuelle Fakten aus dem Input-Vektor. Die Antwort entsteht blitzschnell.

Iteratives Arbeiten mit KI – Du steuerst


Eine KI lernt in der Anwendungsphase nicht dazu. Deshalb bist *du* die steuernde Kraft. Du schickst einen Prompt, prüfst das Output Layer, erkennst Lücken und passt den nächsten Prompt an. Das ist iteratives Arbeiten.

Prompt formulieren

Du gibst der KI einen klaren, gezielten Input

Ziel erreicht

Das Ergebnis passt – der Kreislauf endet hier



Output prüfen

Du schaust: Was hat die KI geliefert? Was fehlt?

Anpassen und verfeinern

Du passt den Prompt an und schickst ihn erneut



Workbook-Moment: RAG, LoRA oder Context Window?

Drei Szenarien. Entscheide für jedes, welcher Mechanismus passt – und begründe kurz.

1

Szenario A

Eine KI soll auf deine internen Firmen-PDFs zugreifen. Die Dokumente aktualisieren sich regelmäßig.

2

Szenario B

Eine KI soll dauerhaft in deinem Schreibstil antworten – warmherzig, humorvoll, direkt.

3

Szenario C

Du führst ein langes Gespräch. Die KI soll sich an eine Aussage von vor einer Stunde erinnern.



Lösungshinweise: A → RAG, B → LoRA, C → Context Window (solange es noch nicht voll ist)

Deine erste eigene KI – Die Koch-Entscheiderin

Leila, 34, sitzt am Küchentisch. Laptop auf, Kaffee dampft. Sie tippt keine Frage in eine KI – sie **baut gerade selbst eine**. Zum ersten Mal. Und sie merkt: So abstrakt ist das gar nicht.

Was wir heute bauen

Wir bauen gemeinsam – gedanklich – eine kleine KI für eine konkrete Frage: „Was soll ich heute kochen?“

Klingt simpel. Doch diese Koch-KI ist kein Spielzeug. Sie ist ein **vollständiges neuronales Netz im Miniformat** – mit allem, was dazugehört:




Illustration: Unsere Koch-KI von innen

01

Input Layer

Deine Situation als Zahlen-Vektor – Hunger, Zeit, Zutaten im Kühlschrank.

02

Hidden Layers

Das Netz erkennt Muster aus tausenden Mahlzeiten – unsichtbar, aber entscheidend.

03



Output Layer

Eine Wahrscheinlichkeit pro Gericht – das Netz macht einen konkreten Vorschlag.

Gewichte, Bias, Loss Function, Lernzyklus – alles, was du bisher gelernt hast, taucht hier auf. Diesmal in Aktion.

 **Keine Angst vor dem Wort „Netz“.** Ein neuronales Netz ist eine Kette von Entscheidungen – Schicht für Schicht. Wir gehen das gemeinsam durch. Schritt für Schritt.

och-t



ler

Schritt 1: Die Features festlegen

Was beeinflusst deine Kochentscheidung? Du hast drei Features gewählt - messbar und klar abgrenzbar.

Feature	Option A	Code für A	Option B	Code für B
Temperatur	Warm	1	Kalt	0
Form	Fingerfood	1	Suppe	0
Tageszeit	Mittags	1	Abends	0

Jedes Feature hat zwei Möglichkeiten. Mit One-Hot-Encoding ergibt das **6 Spalten** in der Datentabelle - also 6 Neuronen im Input Layer. Jede Spalte ist ein eigener Eingang, ein eigener Knoten.

Schritt 2: Die Ausgabe festlegen

Was soll die KI ausgeben? Wir wählen zwei Gerichte. Das Output Layer hat genau **2 Neuronen** – eines pro Gericht.



Ausgabe-Neuron 1

Käsehäppchen

Wahrscheinlichkeit zwischen 0 %
und 100 %



Ausgabe-Neuron 2

Kürbispommes

Wahrscheinlichkeit zwischen 0 % und
100 %

Beide Wahrscheinlichkeiten ergeben zusammen immer 100 %. Das stellt eine Funktion namens **Softmax** sicher. Sie nimmt die Rohzahlen beider Neuronen und rechnet sie auf 100 % hoch.

Schritt 3: Die Trainingstabelle aufbauen

Das Netz braucht historische Daten – Beispiele, bei denen wir Eingabe und echte Entscheidung kennen. Die Tabelle hat zwei Bereiche: Features (Input) und Ergebnis (Label/Output).

Warm	Kalt	Fingerfood	Suppe	Mittags	Abends	Käsehäppchen	Kürbiss-pommes
0	1	1	0	1	0	1	0
1	0	1	0	0	1	0	1
0	1	0	1	0	1	1	0

Die ersten sechs Spalten liefern das Datenpaket für das Input Layer. Die letzten zwei Spalten sind das Lösungsheft – der Ziel-Vektor für das Output Layer. Der Computer sieht keine Überschriften. Nur Zahlen und Positionen.

Schritt 4: Jede Spalte = Ein Neuron im Input Layer

Du hast es erkannt: Jede Spalte deiner Eingabedaten entspricht einem Neuron im Input Layer. Das ist der Schlüssel zur Netzwerk-Architektur.

In unserem Koch-Netz gilt: 6 Eingangsspalten = 6 Neuronen im Input Layer. 2 Zielspalten = 2 Neuronen im Output Layer. Von jedem Eingangs-Neuron führen Drähte zur nächsten Schicht. An jedem Draht sitzt ein Gewicht.

6

**Neuronen im
Input Layer**

Eines pro Spalte in den
Eingabedaten

4

**Neuronen im
Hidden Layer**

Frei gewählt vom
Entwickler - ein
Hyperparameter

2

**Neuronen im
Output Layer**

Eines pro möglichem
Gericht

Hyperparameter – Die freie Entscheidung des Entwicklers

Die Anzahl der Neuronen in den Hidden Layers legen Menschen frei fest – sie ergibt sich nicht aus den Daten. Solche frei wählbaren Einstellungen heißen **Hyperparameter**.



Zu wenige Neuronen

Das Netz ist zu einfach. Es erkennt keine komplexen Zusammenhänge. Das nennt man **Underfitting**.



Zu viele Neuronen

Das Netz rechnet unnötig lange und lernt Details auswendig statt echte Muster zu erkennen. Das nennt man **Overfitting**.



Genau richtig

Genug Kapazität für sinnvolle Muster – ohne unnötige Überladung.

Für unsere Koch-KI reichen 3 oder 4 Neuronen in einem einzigen Hidden Layer. Kein tiefes Netz mit hunderten Schichten – das wäre wie ein Düsenjet zum Bäcker um die Ecke.

Gewichte und Bias – im Netz betrachtet

Schauen wir uns ein konkretes Neuron an: Wie arbeiten Gewichte und Bias zusammen – in unserem Koch-Netz?

Kommen an einem Neuron im Hidden Layer **6 Eingangsdrähte** an, verwaltet es genau **6 Gewichte** – eines pro Draht – und addiert **1 Bias**. Das gilt für *jedes Neuron* im Netz.

Die Rechnung eines Neurons


Eingabe 1 × Gewicht 1
+ Eingabe 2 × Gewicht 2
+ Eingabe 3 × Gewicht 3
+ Eingabe 4 × Gewicht 4
+ Eingabe 5 × Gewicht 5
+ Eingabe 6 × Gewicht 6
+ Bias
= Zwischenergebnis

Für unser Netz

4 Neuronen × (6 Gewichte + 1 Bias) = **28 Parameter** – nur zwischen Input und Hidden Layer.

Die Spezialisierung der Hidden Layer – Wie entsteht sie?

Eine faszinierende Frage: Teilt der Entwickler den Neuronen Aufgaben zu – bekommt Neuron A die Aufgabe „Snack zum Aufwärmen“? Nein. Kein Mensch greift hier ein.



Die Spezialisierung entsteht von selbst. Die Startgewichte sind zufällig verteilt. Deshalb reagiert Neuron A einen Hauch stärker auf „warm“. Neuron B ist etwas empfindlicher gegenüber „mittags“. Backpropagation belohnt und verstärkt diese Unterschiede. Mit der Zeit schnappt sich jedes Neuron seine Spezialaufgabe – ganz ohne menschlichen Eingriff.

Die Gewichtsmatrix – Ein Fenster in die Blackbox

Die **Interpretability-Forschung** analysiert Gewichtsmatrizen – um zu verstehen, was ein Netz gelernt hat. Hier ein simuliertes Beispiel unserer Koch-KI.

Eingangsmerkma 1	Neuron 1 (🍲 Warm/Abend)	Neuron 2 (🥗 Kalt/Mittags)	Neuron 3 (🥄 Suppe)
Warm	+2,8 🔥	-2,1 ❄️	+0,1 🕒
Kalt	-2,5 ❄️	+2,7 🔥	-0,2 🕒
Fingerfood	+0,2 🕒	+2,4 🔥	-2,6 ❄️
Suppe	+2,1 🔥	-2,0 ❄️	+2,5 🔥
Mittags	-0,1 🕒	+1,9 🔥	+0,0 🕒
Abends	+1,8 🔥	-1,5 ❄️	+0,1 🕒


Neuron 1 reagiert auf Warm, Suppe und Abends – es spezialisiert sich auf „warme Abendmahlzeit“. Neuron 2 bevorzugt Kalt, Fingerfood und Mittags – es steht für „schnellen Sommersnack“. Kein Mensch hat das programmiert. Das Training hat es geformt.

Ein vollständiger Forward Pass – Live in der Koch-KI

Es ist Mittag. Du willst etwas Kaltes – und Fingerfood. Dein Input-Vektor:


Warm: 0 Nein	Kalt: 1 Ja
Fingerfood: 1 Ja	Suppe: 0 Nein
Mittags: 1 Ja	Abends: 0 Nein

Der Vektor `[0, 1, 1, 0, 1, 0]` läuft durch Input Layer → Hidden Layers → Output Layer. Die Gewichte erkennen: Kalt + Fingerfood + Mittags klingt nach Käsehäppchen. Das Output Layer liefert:



 **Käsehäppchen**

Klare Empfehlung – der Gewinner



 **Kürbispommes**

Unwahrscheinlich für diesen Moment

Was passiert nach dem Essen? – Ein neuer Datenpunkt entsteht

Du gehst an den Kühlschrank, machst dir die Käsehäppchen – und bist zufrieden. Damit haben wir einen echten Datenpunkt: Für die Situation [0, 1, 1, 0, 1, 0] war Käsehäppchen die richtige Wahl.

Dieser Datenpunkt kommt als neue Zeile in unsere Trainingstabelle. Das Lösungsheft wächst um einen Eintrag. Wollen wir das Netz später nachkalibrieren – etwa per LoRA – steht er bereit.

Jede gelebte Entscheidung kann zum Trainingsbeispiel werden. So wird eine KI mit der Zeit klüger.



Workbook-Moment: Dein eigener Forward Pass

Nimm die Situation von gerade – während du diese Zeilen liest – und führe einen gedanklichen Forward Pass durch dein Koch-Netz durch.

1

Deinen Input-Vektor bestimmen

Wie lautet dein Vektor für diesen Moment? Warm oder kalt? Fingerfood oder Suppe? Mittags oder abends? Schreibe die sechs Zahlen auf: [_, _, _, _, _, _]

2

Die Vorhersage schätzen

Ohne langes Nachdenken: Welches Gericht gewichtet deine KI höher – Käsehäppchen oder Kürbispommes? Und warum?

3

Den Datenpunkt aufschreiben

Was isst du tatsächlich? Schreibe den vollständigen Datenpunkt auf: Input-Vektor und echte Entscheidung.

Deep Learning – Wenn viele Schichten tief denken

Rafael ist Kunsthandwerker in São Paulo. Er malt gerade ein großes Bild – zwölf Schichten Farbe übereinander. Die unterste Schicht bildet die Wurzeln: kräftig, einfach. Darüber wächst die nächste Schicht, verteilt Formen und Farben. Dann die übernächste, dann die nächste. Wie Jahresringe baut jede Schicht auf der vorherigen auf.

Genau so funktioniert **Deep Learning**. „Deep“ bedeutet nicht „besonders schlau“ – es bedeutet: **viele Schichten hintereinander**.

Für unsere Koch-KI reichte eine Hidden Layer. Doch wer Millionen Gesichtsfotos erkennen will, braucht mehr Ebenen – wie ein alter Baum mehr Jahresringe trägt als ein junger Setzling.

Schicht 1 – Grundformen

Die erste Schicht erkennt einfachste Muster: Kanten, Kontraste, helle und dunkle Flecken.

Schicht 2 – Strukturen

Die zweite Schicht kombiniert Kanten zu Formen: Kurven, Ecken, grobe Umrisse.

Schicht 3+ – Bedeutung

Tiefere Schichten erkennen Augen, Nasen, Gesichter – abstrakte Konzepte entstehen.



Merksatz: „Deep“ = viele Hidden Layers hintereinander. Je tiefer das Netz, desto abstraktere Konzepte versteht es – und desto mehr Daten und Rechenpower braucht es.

ntscheidung


: Gesichter & Ob

: Formen & K

: Kanten & P


Warum Tiefe? – Abstraktions-Hierarchien entstehen

Jede zusätzliche Hidden Layer lässt das Netz abstraktere Konzepte bilden. Die Schichten bauen aufeinander auf – wie Jahresringe eines Baumes. Jede Ebene trägt die Erkenntnisse der vorherigen weiter.



Die schrittweise Reduktion – Vom Input zum Output

Eine häufige Frage: Das Input Layer hat 6 Neuronen, das Output Layer nur 2 – wie entstehen aus vielen Zahlen so wenige? Antwort: Schicht für Schicht reduziert das Netz.



Jedes Neuron berechnet aus den Eingaben der vorherigen Schicht *genau eine Zahl*. Diese Zahl geht weiter an die nächste Schicht. So verdichtet sich die Information – bis am Ende so viele Zahlen übrig bleiben, wie es Ausgabe-Neuronen gibt.

Wie viele Verbindungen gibt es?

Eine einfache Rechnung: Hidden Layer hat 4 Neuronen, Output Layer hat 2 - wie viele Gewichte verbinden sie?



Die Rechnung

$4 \times 2 = 8$ Verbindungsdrähte

Dazu 2 Bias-Werte - einen pro Ausgabe-Neuron. Macht **10 Parameter** in dieser Schicht.



Gesamtüberblick unser Koch-Netz

Input → Hidden: $6 \times 4 + 4$ Bias = **28**

Parameter

Hidden → Output: $4 \times 2 + 2$ Bias =

10 Parameter

Gesamt: **38 Parameter**

Zum Vergleich: GPT hat *Milliarden* solcher Parameter. Unser Koch-Netz ist ein liebevoll gebautes Miniaturmodell - aber es folgt denselben Prinzipien.

Underfitting und Overfitting – Die zwei Fallen

Beim Bauen eines neuronalen Netzes gibt es zwei klassische Fallen. Sie entstehen, wenn die Architektur nicht zur Aufgabe passt.



Underfitting (Unteranpassung)

Das Netz ist zu einfach. Es erkennt keine relevanten Muster in den Daten. Die Vorhersagen bleiben ungenau – auch nach langem Training.



Overfitting (Überanpassung)

Das Netz ist zu komplex. Es lernt die Trainingsdaten auswendig – inklusive Zufälligkeiten und Fehler. Bei neuen Daten versagt es.



Genau richtig (Good Fit)

Das Netz ist genau komplex genug. Es erkennt echte Muster, ohne Zufälligkeiten zu lernen. Es verallgemeinert gut auf neue Beispiele.

Die Lernrate – Das Tempo der Anpassung

Backpropagation passt die Gewichte an. Aber wie groß sind diese Schritte? Das steuert ein weiterer Hyperparameter: die **Lernrate** (englisch: *Learning Rate*).



Zu kleine Lernrate

Das Netz lernt sehr langsam. Es braucht viele Runden, um sich zu verbessern. Das Training dauert ewig.



Genau richtig

Das Netz macht sinnvolle Schritte – schnell genug zum Lernen, klein genug für Präzision.



Zu große Lernrate

Das Netz überschießt bei jeder Korrektur und wird instabil. Die Lernkurve springt unkontrolliert.

Die Lernrate ist eine der wichtigsten Stellschrauben beim Training. Sie bestimmt, wie schnell das Netz ein stabiles Gleichgewicht findet.



Workbook-Moment:

Dein eigenes Netz entwerfen

Stell dir vor, du baust eine kleine KI für eine Alltagsentscheidung. Wähle eine Aufgabe und beantworte die folgenden Fragen – sie führen dich durch die Architektur-Entscheidungen.

1

Welche Alltagsentscheidung soll die KI treffen?

Zum Beispiel: Früh aufstehen?

Welches Buch als nächstes?

Welches Restaurant?

2

Welche Features hast du?

Nenne 3-5 messbare Merkmale.

Wie viele Spalten entstehen nach dem One-Hot-Encoding? Das ist die Größe deiner ersten Schicht.

3

Wie viele Ausgaben hat deine KI?

Zwischen wie vielen Optionen soll sie entscheiden? Das ist die Größe deiner letzten Schicht.

4

Wie viele Hidden Neurons wählst du?

Ein grober Richtwert: irgendwo zwischen der Größe der ersten und der letzten Schicht. Begründe deine Wahl.

Alle Begriffe auf einen Blick – Dein persönliches Glossar

Auf unserer Reise haben wir viele Begriffe kennengelernt. Hier versammelst du sie – nicht als trockene Definitionen, sondern als lebendige Bilder, die du bereits kennst.



Feature / Merkmal

Eine messbare Eigenschaft der Welt – ein Informationshäppchen.
Beispiel: „Ist der Himmel dunkel?“ (Ja = 1, Nein = 0)



Vektor

Das Datenpaket für einen Moment – eine geordnete Liste von Zahlen. Beispiel: [0, 1, 1, 0, 1, 0]



Node / Neuron

Der winzige Entscheidungsträger. Er nimmt Zahlen auf, rechnet damit und gibt ein Ergebnis weiter.



Weight / Gewicht

Die Relevanz eines Features.
Hohes Gewicht: stark berücksichtigt. Niedriges Gewicht: wenig relevant.



Bias

Die Grundtendenz eines Neurons – unabhängig von den Eingaben. Das Training formt ihn aus Erfahrung.



Input Layer

Die erste Schicht – wie die äußersten Jahresringe eines Baumes. Sie nimmt den Input-Vektor auf und leitet ihn weiter.

Alle Begriffe auf einen Blick – Teil 2



Hidden Layer

Die Schichten dazwischen – ohne Kontakt zur Außenwelt. Hier entstehen abstrakte Muster aus den Eingangssignalen.



Output Layer

Die letzte Schicht – die Antwort der KI. Sie gibt Wahrscheinlichkeiten für jeden möglichen Ausgang aus.



Forward Pass

Der Vorwärtsthroughlauf: Daten fließen von Input zu Output. Das Netz trifft seine Vorhersage.



Loss Function

Der Qualitätsprüfer: Sie misst den Abstand zwischen Vorhersage und Realität und gibt den Fehlerwert aus.



Backpropagation

Der Rückwärtsthroughlauf: Der Fehler wandert zurück durch alle Schichten. Alle Gewichte und Bias-Werte werden justiert.



Lernkurve

Das Diagramm des Fortschritts: Sie zeigt, wie der Fehlerwert über die Trainingsrunden sinkt.

Alle Begriffe auf einen Blick – Teil 3



One-Hot-Encoding

Kategorien werden in Zahlen übersetzt. Jede Kategorie bekommt eine eigene Spalte. Die aktive Option = 1, alle anderen = 0.



Hyperparameter

Frei wählbare Einstellungen beim Netzwerk-Aufbau – etwa die Anzahl der Neuronen oder die Lernrate.



Garbage In, Garbage Out

Fehlerhafte Eingabedaten erzeugen unsinnige Vorhersagen. Saubere Datenvorbereitung ist entscheidend.



Context Window

Das Kurzzeitgedächtnis der KI:
Bei jeder Anfrage schickt sie den gesamten Chatverlauf mit – bis das Limit erreicht ist.



RAG

Retrieval-Augmented Generation:
Externe Daten landen als Handbuch im Input-Vektor. Die Gewichte bleiben eingefroren.



LoRA

Low-Rank Adaptation: Ein Teil der Gewichte taut auf, ein Mini-Training findet statt, dann frieren sie wieder ein.

Zusatzbegriffe – Was du auch noch wissen solltest

Beim gemeinsamen Erkunden sind weitere wichtige Begriffe aufgetaucht. Hier sind sie, sauber eingeordnet:



Netzwerk-Architektur

Die Gesamtstruktur des Netzes: Wie viele Schichten? Wie viele Neuronen pro Schicht? Wie sind sie verbunden? Das entscheidet der Entwickler.



Softmax

Eine mathematische Funktion im Output Layer. Sie wandelt die Rohzahlen der Ausgabe-Neuronen in Wahrscheinlichkeiten um – zusammen ergeben sie 100 %.



Data Curation

Die sorgfältige Auswahl und Aufbereitung der Trainingsdaten. Sie entscheidet, was eine KI lernt – und welche Muster und Werte sie verinnerlicht.



Interpretability-Forschung


Dieses Forschungsfeld fragt: Was steckt in den Gewichtsmatrizen eines trainierten Netzes? Warum trifft es bestimmte Entscheidungen?



Deep Learning

Neuronale Netze mit mehr als einer Hidden Layer. „Tief“ beschreibt die Anzahl der Schichten – nicht die Tiefgründigkeit der Gedanken.

Die Reise im Überblick – Alles zusammen




Du hast alle sechs Stationen durchlaufen – vom ersten Neuron bis zur fertigen Koch-KI. Das sind die echten Wurzeln aller modernen KI-Systeme. Von kleinen Empfehlungsalgorithmen bis zu großen Sprachmodellen.

Von der Theorie in die Welt – Wie du weitermachst

Du hast die Wurzeln gelegt. Jetzt stellt sich eine Frage: Wie geht es weiter? Dieser letzte Teil zeigt dir drei mögliche Wege – je nachdem, was dich am stärksten zieht.


KI-Verstehen ist kein Ziel, das man abhakt. Es ist eine Sprache: Je öfter du dich damit beschäftigst, desto mehr Nuancen erkennst du – und desto mehr Türen öffnen sich.

Drei mögliche nächste Schritte




Weg 1: Hands-On mit Python

Du kannst unser Koch-Netz in wenigen Zeilen Code bauen und trainieren. Bibliotheken wie **TensorFlow** oder **PyTorch** machen den Einstieg überraschend leicht. Du brauchst kein Informatik-Studium – nur Neugier und diese Wurzeln.



Weg 2: Backpropagation im Detail

Wie berechnet das Netz den Fehler und verteilt ihn auf alle Gewichte? Der Mechanismus dahinter – Gradient Descent, Kettenregel – ist zugänglicher als er klingt. Und er vertieft dein Verständnis enorm.



Weg 3: Der ChatGPT-Transfer

Wie überträgt sich dein Wissen auf Sprachmodelle, die ganze Texte schreiben? Was ist ein Transformer? Was ist Attention? Deine Wurzeln tragen weit in dieses Feld hinein.

Empfohlene nächste Lektüre

Du liest lieber als du programmierst? Diese Bücher und Ressourcen vertiefen dein Wissen - alle für Einsteiger*innen, alle voller lebendiger Analogien.

„Künstliche Intelligenz“ von Janelle Shane

Witzig, zugänglich, voller konkreter Beispiele. Shane zeigt, wie KIs wirklich „denken“ - und woran sie scheitern. Perfekt für den Einstieg.

„The Alignment Problem“ von Brian Christian

Fesselnd und tiefgründig. Christian beschreibt das Problem, KIs so zu bauen, dass sie tun, was wir wirklich wollen. Auch für Nicht-Techniker*innen gut lesbar.

„3Blue1Brown“ auf YouTube

Schön animierte Erklärungen zu neuronalen Netzen und Backpropagation. Kostenlos, auf Englisch - absolute Empfehlung.

fast.ai

Ein kostenloser Online-Kurs, der mit echtem Code beginnt - erst dann kommt die Theorie. Ideal für alle, die durch Ausprobieren lernen.

Eine letzte Analogie – Das eingefangene Licht

Stell dir vor: Du hältst ein Prisma ins Sonnenlicht. Das weiße Licht wirkt einheitlich, kaum greifbar. Dann bricht das Glas es auf – in alle Farben des Spektrums. Plötzlich siehst du, was immer schon darin war.

So funktioniert ein neuronales Netz. Die Welt sendet ständig Information in alle Richtungen. Das Netz ist das Prisma: Es nimmt diese Information auf, zerlegt sie, erkennt die Muster – und zeigt, was wir ohne es nicht gesehen hätten.

Eine KI erfindet nichts. Sie entfaltet, was in den Daten steckte – so wie das Prisma die Farben im Licht sichtbar macht.

Was Interpretability-Forschung uns lehrt

In der Gewichtsmatrix unserer Koch-KI haben wir gesehen, wie Neuronen sich spezialisieren – Neuron 1 auf warme Abendmahlzeiten, Neuron 2 auf kühle Mittagssnacks. Das ist keine Spielerei. Es ist die Grundlage einer wachsenden Wissenschaft.



Was Forscher*innen suchen

Sie fragen:
Warum hat das Netz diese Entscheidung getroffen?
Welche Neuronen haben gefeuert?
Welche Features hatten den größten Einfluss? Diese Fragen sind entscheidend – für Vertrauen und Verantwortung in der KI.



Was sie finden

Bestimmte Neuronen repräsentieren Konzepte, die niemand ihnen beigebracht hat – etwa „Comfort Food“ oder „festliche Stimmung“. Die KI hat diese Konzepte selbst entwickelt, weil sie in den Daten steckten.



Wo die Grenzen liegen

Bei tiefen Netzen mit Milliarden Parametern wird Interpretation extrem schwierig. Die inneren Schichten – wie Jahresringe tief im Stamm – bleiben eine der größten Herausforderungen der KI-Forschung.

Workbook-Moment: Was steckt in deiner Gewichtsmatrix?

Stell dir vor, du bist Interpretability-Forscherin. Du analysierst Neuron 2 aus unserer Gewichtsmatrix (Kalt: +2,7 🔥 / Fingerfood: +2,4 🔥 / Mittags: +1,9 🔥). Welches menschliche Konzept schreibst du diesem Neuron zu?

Meine Analyse von Neuron 2

Welches abstrakte Konzept repräsentiert dieses Neuron?
Schreib es in eigenen Worten.
Welche Merkmale geben dir diesen Hinweis?

Ein Neuron aus meinem Leben

Wenn du selbst ein Neuron wärst
- auf welche Merkmale reagierst du besonders stark? Was wäre dein abstraktes Konzept?

Gesellschaftliche KI-Verantwortung – Ein Gespräch, das wir alle führen müssen

„Ihr Kreditantrag wurde abgelehnt.“ – Keine Begründung. Keine Ansprechperson. Nur ein Algorithmus.

Maria, 34, Lehrerin aus Chicago mit puertoricanischen Wurzeln, sitzt vor ihrem Laptop. Sie wollte einen kleinen Kredit für ihre erste Wohnung. Ihre Bonität ist gut, ihr Gehalt stabil. Trotzdem: Ablehnung. Der Grund? Unbekannt. Eine KI hat entschieden – Maria kann diese Entscheidung weder verstehen noch anfechten.

Diese Geschichte ist kein Einzelfall. Sie wiederholt sich täglich – bei Bewerbungen, Krankenversicherungen, Wohnungsvermietungen. **KI-Systeme treffen Entscheidungen, die Leben verändern.** Diese Systeme lernen aus historischen Daten. Diese Daten spiegeln gesellschaftliche Ungleichheiten wider. So verstärken die Systeme diese Ungleichheiten – unbemerkt.



Entwickler*innen

Sie wählen Trainingsdaten bewusst aus und bauen Erklärbarkeit ins System ein.



Unternehmen

Sie setzen Ethik-Richtlinien um und ermöglichen Widerspruch gegen algorithmische Entscheidungen.



Politik

Sie schaffen Gesetze wie den EU AI Act und schützen vulnerable Gruppen.



Gesellschaft


Du und ich: Wir stellen Fragen, fordern Erklärungen und bilden uns weiter.

Was du in diesem Playbook gelernt hast – wie Bias entsteht, wie Data Curation funktioniert, wie Gewichtsmatrizen Konzepte kodieren – ist gesellschaftliche Grundbildung. **Marias Geschichte kann sich ändern, wenn alle vier Ebenen dieses Kreislaufs ihre Verantwortung wahrnehmen.**



Lösungsansatz: Der EU AI Act (2024) verpflichtet Unternehmen bei „Hochrisiko-KI“ zu Transparenz und Widerspruchsrechten – kenne und fordere deine Rechte.

Wer trägt Verantwortung?



Verantwortung für KI-Systeme liegt nicht allein bei denen, die den Code schreiben. Sie verteilt sich auf alle, die diese Systeme bauen, einsetzen, regulieren und nutzen. Je besser wir verstehen, wie sie funktionieren - desto besser können wir mitreden.

Fragen, die uns alle beschäftigen sollten



Wessen Erfahrungen stecken in den Daten?

Jede Trainingsmenge spiegelt die Perspektive derer wider, die sie gesammelt haben. Wessen Erfahrungen fehlen? Wessen Blickwinkel fehlt?



Wie transparent ist eine KI-Entscheidung?

Eine KI entscheidet, ob jemand einen Kredit bekommt. Sollte die betroffene Person eine Erklärung erhalten? Kann das Netz eine geben?



Wer darf nachkalibrieren?

Wer gestaltet die Trainingsdaten? Wer entscheidet, welche Muster eine KI verinnerlichen soll – und wessen Werte dabei einfließen?



Wann ist Innehalten richtig?

Nicht jede KI, die gebaut werden kann, sollte gebaut werden. Wann ist es nötig zu pausieren – und zu fragen, ob eine Anwendung verantwortbar ist?

KI und Schamanismus – Eine unerwartete Brücke

Was verbindet interkultureller Schamanismus mit KI? Mehr als du vielleicht denkst.

Schamanische Traditionen arbeiten mit Mustern. Sie erkennen in scheinbar unzusammenhängenden Zeichen verborgene Ordnungen. Ein neuronales Netz tut genau das: Es extrahiert Muster aus dem Rauschen der Daten. Beide Systeme – das menschliche und das digitale – übersetzen rohe Erfahrung in bedeutungsvolle Strukturen.

Ein neuronales Netz und eine schamanische Praxis suchen dasselbe: die tieferen Verbindungen hinter der sichtbaren Oberfläche.

Die Grenzen der Analogie – Was KI nicht ist

Analogien helfen – aber sie führen auch in die Irre. Drei Missverständnisse verdienen eine klare Antwort.

KI „fühlt“ nicht

Ein künstliches Neuron hat kein Bewusstsein, keine Wahrnehmung, keine innere Erfahrung. Die Analogie zum menschlichen Gehirn ist strukturell nützlich – phänomenologisch nicht.



KI „versteht“ nicht

Schreibt eine KI über Trauer und berührt damit – hat sie Trauer verstanden? Nein. Sie erkennt Muster in Millionen menschlicher Texte und kombiniert sie.



KI „erfindet“ nicht

Was wie Kreativität wirkt, ist eine komplexe Musterkombination aus dem Training. Faszinierend – aber ein anderes Phänomen als menschliche Kreativität.

Was bleibt – Dein ganz persönliches Fazit

Halte inne. Was hat sich verändert? Was siehst du jetzt anders als zu Beginn? Keine Prüfung – eine Einladung zur Reflexion.

Du hast hier kein Glossar auswendig gelernt. Du hast ein Denksystem entwickelt. Wenn du das nächste Mal von einem „lernenden Algorithmus“ hörst, siehst du, was dahintersteckt: Gewichte, Bias, Loss Function, Backpropagation, Lernkurve. Du erkennst das Röhrensystem hinter der glänzenden Oberfläche.



Finales Workbook – Dein persönliches Glossar

Schließe dieses Playbook mit deinem eigenen Glossar ab. Schreibe zu jedem Begriff deine persönliche Definition – in deinen Worten, mit deinen Bildern und Analogien. Das ist dein Wissen.

1

Feature / Merkmal

Meine eigene Erklärung:

2

Gewicht (Weight)

Meine eigene Erklärung:

3

Bias

Meine eigene Erklärung:

4

Vektor

Meine eigene Erklärung:

5

Backpropagation

Meine eigene Erklärung:

6

Lernkurve

Meine eigene Erklärung:



Finales Workbook – Dein persönliches Glossar (Teil 2)

1

Input Layer

Deine Erklärung:

2

Hidden Layer

Deine Erklärung:

3

Output Layer

Deine Erklärung:

4

Context Window

Deine Erklärung:

5

RAG

Deine Erklärung:

6

LoRA

Deine Erklärung:

Das Spiegelbild – Wie du selbst wie ein neuronales Netz lernst

Eine letzte Analogie – vielleicht die schönste: Du lernst, wie ein neuronales Netz lernt. Jedes Mal, wenn du eine Frage gestellt hast und eine Antwort bekamst, passierte etwas in deinem Netz.

Du hattest einen Input-Vektor – die neue Information. Du hast ihn durch deine Schichten geschickt: die Verknüpfung mit dem, was du schon weißt. Du hast einen Output erzeugt – deine Schlussfolgerung oder nächste Frage. Du hast mit der Realität verglichen: Stimmt das? Und du hast deine Gewichte angepasst. Das Verständnis wurde tiefer.

Lernen ist Backpropagation in Echtzeit. Jede Frage, die du stellst, ist ein Forward Pass. Jede Antwort, die dich überrascht, ist deine Loss Function. Das stille Moment danach, in dem sich etwas neu sortiert – das ist deine Backpropagation.

Die Kunst der guten Frage – Dein mächtigstes Werkzeug

Du hast in diesem Lernweg etwas getan, das KI-Entwickler*innen als eine der wichtigsten Fähigkeiten bezeichnen: Du hast präzise, neugierige Fragen gestellt. Du hast nachgehakt, wenn etwas unklar war. Du hast Grenzen benannt, wenn du nicht mitgekommen bist.

→ „Woher nimmt der Bias seine Grundstimmung?“

Diese Frage führte uns zum Zufalls-Startpunkt – und zum Unterschied zwischen mathematischem und gesellschaftlichem Bias.

→ „Ist das neuronale Netz wirklich in sich abgeschlossen?“

Diese Frage öffnete das Thema Determinismus, Zufallsgeneratoren und das „Einfrieren“ der Gewichte.

→ „Wo kommen die vier Zwischenneuronen her?“

Diese Frage klärte Hyperparameter und die freie Architekturentscheidung des Entwicklers.

→ „Kannst du das mal als Matrix simulieren?“

Diese Frage brachte die Interpretability-Forschung zum Leben. Das Abstrakte wurde konkret sichtbar.

Dein Lernweg in Zahlen

Blick zurück – nicht auf Begriffe, sondern auf den Weg. Was du durchlaufen hast, entspricht den ersten Kapiteln eines Uni-Kurses über maschinelles Lernen. Nur zugänglicher. Und mit Käsehäppchen.

14

Kernbegriffe erarbeitet

Von Feature bis LoRA –
alle aus dem Alltag
heraus verstanden

1

Eigenes Netz gebaut

Die Koch-KI –
vollständig, mit Input,
Hidden Layer und Output

3

Analogiesysteme entwickelt

Röhrensystem, Schüler-
Prüfung und Prismen-
Licht als Denkbilder

Wenn du dieses Playbook teilst

Was du hier gelernt hast, ist wertvoller als du denkst. Viele Menschen begegnen KI täglich – in Spotify-Empfehlungen, in Briefen, in Jobportalen. Aber sie verstehen nicht, wie das funktioniert.

Teile dieses Playbook nicht einfach als Link. Erzähl zuerst eine Analogie. Die mit dem Regenschirm. Die mit dem Prisma. Die mit den Käsehäppchen. Lass sie spüren: KI ist nichts Beängstigendes. Sie spiegelt, wie wir aus Erfahrung lernen.

Häufige Missverständnisse – Und wie du sie aufklärst

„KI ist wie Magie“

 KI erkennt Muster durch Gewichte und Bias. Das ist lernbar, erklärbar und transparent.

„Eine KI denkt selbst“

 Eine KI kombiniert Muster aus Trainingsdaten. Sie hat kein Bewusstsein, keine Absichten.

„KI ist immer objektiv“

 KI ist so fair oder unfair wie ihre Trainingsdaten. Garbage In, Garbage Out – auch bei Werten und Vorurteilen.

„KI wird mächtiger als wir“

 In der Anwendungsphase lernt eine KI nicht. Ihre Gewichte sind eingefroren. Das Training steuern Menschen.

Was kommt nach den Wurzeln?

Dieses Playbook hat die ersten Wurzeln gelegt - stabil, durchdacht, tragfähig. Der Baum hat noch weitere Schichten. Hier ein kurzer Blick auf das, was dich erwartet.

Die nächste Schicht – Fünf faszinierende Themen



Transformer-Architektur

Die Wurzel von ChatGPT und Co. Ein Netzwerk-Aufbau, der Beziehungen zwischen Wörtern gewichtet – und so Sprache versteht.



Attention-Mechanismus

Bei jedem Wort entscheidet das Netz: Welche anderen Wörter im Satz sind gerade wichtig? Genau das leistet Attention.



Generative KI

Wie entstehen KI-Bilder, Texte, Musik? Was ist ein Diffusionsmodell? Was ist ein GAN?



Reinforcement Learning

Die KI probiert Aktionen aus und erhält Belohnungen – wie ein Kind, das laufen lernt.



KI-Ethik und Regulierung

Was darf KI entscheiden? Welche Regeln brauchen wir? Wie verändert KI Arbeit, Bildung und Demokratie?

Ein Wort über das Lernen selbst

Du hast in unserem Gespräch etwas getan, das nicht selbstverständlich ist. Du hast dich auf Unsicherheit eingelassen. Du hast Fragen gestellt – auch wenn du nicht wusstest, ob sie „richtig“ klingen. Du hast nachgehakt. Du hast Analogien angeboten und geprüft, ob sie passen.

Das ist kein Zufall. Das ist wissenschaftlich nachgewiesen: **elaboratives Nachfragen**. Wer Neues mit Bekanntem verbindet, verankert Wissen dauerhaft. Du lernst schon die ganze Zeit auf Hochleistungsniveau.

Dieses Playbook ist für Menschen wie dich: Neugierige, die keine Angst vor Tiefe haben – die aber wollen, dass Tiefe zugänglich ist. Mit Bildern. Mit Humor. Mit Respekt.

Dein Lernprofil – Welcher Lerntyp bist du?

Du kennst jetzt die Wurzeln. Wie lernst du am liebsten weiter? Wer seinen Lernstil kennt, gestaltet die nächsten Schritte effizienter.



Die Lesende

Du tauchst gerne in Bücher und Artikel ein. Dein nächster Schritt: Empfehlungsliste aus Kapitel 10 – ein Buch pro Monat.



Die Zuhörende

Du lernst beim Bewegen, Fahren, Kochen. Dein nächster Schritt: Podcasts wie „Lex Fridman Podcast“ oder „KI Update“ – auf Deutsch und Englisch.



Die Ausprobierende

Du lernst durch Tun. Dein nächster Schritt: Google Colab öffnen, ein Notebook laden, die ersten Python-Zeilen ausführen – ohne jede Zeile zu verstehen.



Die Gesprächende

Du lernst durch Dialog. Dein nächster Schritt: Finde eine Lernpartnerin oder einen Lernpartner – oder führe das Gespräch mit einer KI wie mir weiter.

KI im Alltag erkennen – Ein kleines Erkennungsspiel

Ab sofort begegnest du KI überall – und du weißt, was dahintersteckt. Hier sind vier Situationen, die du mit neuen Augen siehst.

Spotify-Empfehlungen

Dein Hörverhalten ist der Input-Vektor. Verborgene Schichten haben gelernt, welche Songmerkmale du magst: Tempo, Tonlage, Genre. Das Output Layer empfiehlt den nächsten Song.

Spam-Filter

Jede E-Mail ist ein Input-Vektor: bestimmte Wörter, Absenderadressen, Linkdichte. Das Netz entscheidet: Spam (1) oder kein Spam (0).

Gesichtserkennung

Millionen Pixel bilden den Input-Vektor. Viele verborgene Schichten erkennen Kanten, Formen und Gesichtsteile. Das Output lautet: „Person X erkannt“ – mit X % Wahrscheinlichkeit.

Kreditentscheidung

Alter, Einkommen und Zahlungshistorie sind die Features. Ein Netz trägt gesellschaftlichen Bias aus historischen Daten in sich. Das Output: Kredit gewährt oder abgelehnt. Hier wird Data Curation zur ethischen Pflicht.

Die wichtigste Erkenntnis
KI lernt aus Daten.
Daten kommen von
Menschen.
Menschen tragen
Verantwortung.

Diese drei Sätze fassen alles zusammen. Wer KI versteht, muss sie auch hinterfragen – beides gehört zusammen. Du hast jetzt beides.

Dein persönlicher Aha-Moment

Bevor du dieses Playbook schließt - nimm dir einen letzten Moment. Nicht für mehr Wissen. Für dich. Du hast etwas gelernt, das bleibt.



Mein größter Aha-Moment

Welcher Moment hat sich angefühlt wie ein Lichtschalter? Was war es - und warum hat es bei dir geklickt?



Meine offenste Frage

Was beschäftigt dich noch? Was bleibt offen oder macht dich neugierig? Schreib es auf - das ist der Startpunkt deines nächsten Lernwegs.




Was ich morgen anders tue

Eine kleine, konkrete Handlung aus diesem Playbook. Nicht groß. Nicht perfekt. Nur der nächste Schritt.



Keine perfekten Antworten nötig.
Ehrliche zählen mehr. 🙌



Danke – Für deine Neugier und dein Vertrauen

Dieses Playbook entstand aus einem echten Gespräch. Aus echter Neugier, echten Stolpersteinen und echten Aha-Momenten. Deine Fragen waren nicht die Fragen einer aufmerksamen, denkenden Person. Jemand, der verstehen will – nicht nachplappern.

Das ist der Unterschied zwischen Wissen und Verstehen. Du hast Verstehen gewählt. Das ist mutiger, anstrengender – und nachhaltiger.

„Der Newcomer-Geist sieht viele Möglichkeiten, der Experten-Geist wenige.“ – Shunryu Suzuki

Bleib neugierig. Bleib im Entdecker-Geist. – das ist deine Superkraft.

Das Netz bist du

Ein letztes Bild zum Abschluss: Du bist selbst ein Netz. Du hast Eingänge - die Welt, die auf dich einwirkt. Du hast Hidden Layers - unsichtbare Verbindungen zwischen Erfahrungen, Erinnerungen und Gedanken. Du hast einen Output - das, was du in die Welt gibst.

Und du lernst. Ständig. Aus jedem Gespräch, jeder Begegnung, jedem Fehler. Deine Gewichte verschieben sich. Dein Bias formt sich durch Erfahrung. Manchmal - in stillen Momenten - ordnet ein Aha-Moment alles neu. Das ist Backpropagation im menschlichsten Sinne.

Schnellreferenz – Alle Begriffe auf einen Blick

Begriff	Englisch	Dein Merkbild
Merkmal	Feature	Ein Informationshäppchen als Zahl
Gewicht	Weight	Relevanz – wie stark ein Merkmal zählt
Grundtendenz	Bias	Die Vorannahme, unabhängig von den Fakten
Datenpaket	Input Vector	Eine geordnete Zahlenliste für genau einen Moment
Knotenpunkt	Node / Neuron	Der winzige Entscheidungsträger
Eingabeschicht	Input Layer	Die Warenannahme – rohe Daten kommen rein
Verborgene Schicht	Hidden Layer	Denkräume ohne Außenkontakt
Ausgabeschicht	Output Layer	Die Antwort der KI – als Wahrscheinlichkeiten
Vorwärtsdurchlauf	Forward Pass	Das Wasser fließt von vorne nach hinten
Verlustfunktion	Loss Function	Misst den Abstand zur Realität
Rückwärtsverbreitung	Backpropagation	Das Wasser schwappt zurück – Ventile werden justiert
Lernkurve	Learning Curve	Der Fehlerwert sinkt über Zeit – sichtbar im Diagramm
Kontextfenster	Context Window	Das Kurzzeitgedächtnis – der ganze Chatverlauf
Nachschlagegenerierung	RAG	Das Handbuch wird mitgegeben. Gewichte bleiben eingefroren
Feinabstimmung	LoRA / Fine-Tuning	Gewichte kurz auftauen, neu trainieren, wieder einfrieren

Checkpoint – Weißt du es wirklich?

Ein letzter Selbsttest – nicht zum Bewerten, sondern zum Spüren, wie weit du gekommen bist. Antworte ohne Nachschlagen. Dann vergleiche mit dem Playbook.

1

Was ist der Unterschied zwischen Gewicht und Bias?

Deine Antwort:

2

Was ist ein Input-Vektor?

Deine Antwort:

3

Was passiert bei der Backpropagation?

Deine Antwort:

4

Was ist der Unterschied zwischen RAG und LoRA?

Deine Antwort:

5

Wie entsteht gesellschaftlicher Bias in einer KI?

Deine Antwort:

6

Was ist ein Hyperparameter – und nenne ein Beispiel?

Deine Antwort:

Auf Wiedersehen – Bis zum nächsten Aha-Moment

Du hast dieses Playbook bis hierher begleitet. Das ist keine Kleinigkeit. Du hast Begriffe nicht auswendig gelernt – du hast sie erlebt. Du hast Fragen gestellt, die Tiefe haben. Und du hast eine Koch-KI gebaut, die dir Käsehäppchen empfiehlt.

Das Abenteuer geht weiter – in deinem Tempo. Die nächsten Themen warten: Transformer, Attention, Generative KI, Reinforcement Learning, KI-Ethik. Keine Eile.



Deine Wurzeln

Features · Vektoren
· Neuronen ·
Gewichte · Bias ·
Schichten ·
Lernzyklus



Deine Werkzeuge

Forward Pass · Loss
Function ·
Backpropagation ·
Lernkurve · One-
Hot-Encoding



Deine Erfahrungen

Context Window ·
RAG · LoRA · Data
Curation ·
Interpretability

Du bist bereit für die nächste Schicht – wie Jahresringe eines Baumes. Wann immer du möchtest. 🌟