

SERI BELAJAR AI

BELAJAR AI

Panduan Lengkap dari Nol hingga Paham

10 Tahap Memahami Kecerdasan Buatan, Machine Learning, dan Large Language Model —
dari Sejarah, Cara Kerja, hingga Cara Memilih Model yang Tepat

Disusun oleh Badar M Y dan Temannya

Edisi Pertama · Juli 2026

BELAJAR AI

Panduan Lengkap dari Nol hingga Paham

10 Tahap Memahami Kecerdasan Buatan, Machine Learning, dan Large Language Model —
dari Sejarah, Cara Kerja, hingga Cara Memilih Model yang Tepat

Disusun oleh Badar M Y dan Temannya

Edisi Pertama · Juli 2026

Kata Pengantar

Buku ini lahir dari sebuah percakapan sederhana: rasa ingin tahu tentang apa sebenarnya yang membedakan Claude, ChatGPT, Grok, dan model-model AI lain yang belakangan makin sering disebut orang. Dari satu pertanyaan itu, pembahasan berkembang tahap demi tahap — dari “apa itu AI” sampai ke sejarah teknisnya, cara kerja machine learning, logika di balik large language model, hingga cara memilih model yang tepat untuk kebutuhan sehari-hari.

Sepuluh tahap pembelajaran itu kini dirangkum menjadi satu buku utuh. Setiap bab disusun dengan pola yang sama: penjelasan konsep secara bertahap dan sesederhana mungkin, diikuti studi kasus mudah yang menghubungkan teori dengan situasi sehari-hari, supaya konsep yang tadinya terasa teknis dan asing bisa benar-benar melekat.

Buku ini ditulis untuk siapa pun yang belum pernah menyentuh istilah AI sama sekali — tidak ada asumsi pengetahuan teknis sebelumnya. Selamat membaca, dan semoga setelah menyelesaikan buku ini, percakapan seputar AI tidak lagi terasa membingungkan.

— *Badar M Y dan Temannya*

Daftar Isi

Bab 1 — Apa itu AI (Kecerdasan Buatan)?	5
Bab 2 — Apa itu Machine Learning?	8
Bab 3 — Apa itu Large Language Model (LLM)?	10
Bab 4 — Training vs Inference	13
Bab 5 — Istilah Kunci (Glosarium Lengkap)	14
Bab 6 — Pemain Besar di Dunia AI	16
Bab 7 — Ragam Model & Cara Memilih Model yang Tepat	17
Bab 8 — Kesalahpahaman Umum tentang AI	19
Bab 9 — Langkah Praktis Terus Belajar	20
Lampiran A — Perbandingan Model Claude	21

BAB 1

Apa itu AI (Kecerdasan Buatan)?

Fondasi teori, sejarah, dan pola visual Symbolic vs Connectionist AI

AI adalah program komputer yang dibuat untuk meniru kemampuan berpikir manusia: mengenali pola, membuat keputusan, atau menghasilkan sesuatu (teks, gambar, suara) tanpa manusia menuliskan instruksi eksplisit untuk setiap kemungkinan situasi. Berbeda dari program biasa yang mengikuti aturan tetap, AI “belajar” polanya sendiri dari data dalam jumlah sangat besar.

1.1 Fondasi Teori: Neuron Buatan McCulloch & Pitts (1943)

Warren McCulloch (neurofisiologis) dan Walter Pitts (matematikawan) menerbitkan makalah “*A Logical Calculus of the Ideas Immanent in Nervous Activity*” pada 1943. Mereka mengusulkan model matematis sederhana dari neuron biologis: sebuah “neuron buatan” menerima beberapa sinyal masukan (angka), menjumlahkannya, lalu menghasilkan output biner (aktif/tidak aktif) berdasarkan apakah jumlah tadi melewati ambang batas (threshold) tertentu.

Kenapa penting: ini adalah pembuktian matematis pertama bahwa jaringan neuron sederhana bisa merepresentasikan operasi logika (AND, OR, NOT) — menjembatani biologi otak dengan logika komputasi. Inilah cikal bakal konsep neural network yang dipakai sampai deep learning modern.

1.2 Logic Theorist (1956)

Dibuat oleh Allen Newell, Herbert Simon, dan Cliff Shaw — sering disebut sebagai **program AI pertama di dunia**. Tujuannya: membuktikan teorema matematika dari buku *Principia Mathematica* (Whitehead & Russell) secara otomatis, meniru cara manusia berpikir logis langkah demi langkah. Program ini berhasil membuktikan 38 dari 52 teorema di bab pertama, bahkan menemukan satu pembuktian yang lebih elegan dari versi aslinya.

Kenapa penting: ini adalah contoh nyata pertama pendekatan *Symbolic AI* — merepresentasikan pengetahuan sebagai simbol logika dan mencari solusi lewat pencarian (search) dalam ruang kemungkinan.

1.3 “AI Winter”

Istilah untuk periode ketika pendanaan dan minat riset AI menurun drastis karena hasil nyata tidak sesuai janji besar yang sebelumnya digembar-gemborkan. **AI Winter pertama** (pertengahan 1970-an–awal 1980-an) dipicu laporan kritis seperti Lighthill Report (1973), ditambah keterbatasan matematis neural network sederhana yang dibuktikan Minsky & Papert dalam buku *Perceptrons* (1969). **AI Winter kedua** (akhir 1980-an–awal 1990-an) dipicu jatuhnya pasar expert systems yang mahal dirawat dan sulit diskalakan.

Pelajaran penting: AI berulang kali mengalami siklus hype berlebihan lalu kekecewaan — pola ini relevan untuk menilai klaim-klaim AI hari ini secara realistis.

1.4 “Expert Systems”

Muncul populer di era 1980-an sebagai gelombang kedua Symbolic AI. Pakar manusia (mis. dokter) “menuangkan” pengetahuannya jadi ribuan aturan IF-THEN eksplisit ke dalam sistem. Contoh terkenal: MYCIN (diagnosis infeksi bakteri), DENDRAL (analisis struktur kimia), dan XCON (konfigurasi komputer di DEC — menghemat jutaan dolar per tahun).

Kelemahan fatal: sangat mahal dan lambat dirawat/diperbarui, tidak bisa menangani situasi di luar aturan yang sudah ditulis, dan tidak bisa “belajar sendiri”. Inilah salah satu penyebab utama AI Winter kedua.

1.5 Deep Learning

Deep learning adalah evolusi dari Connectionist AI (neural network) dengan banyak lapisan (layer) tersembunyi. Idennya sudah ada sejak 1980-an (algoritma backpropagation dipopulerkan Geoffrey Hinton, David Rumelhart, dan Ronald Williams pada 1986), tapi baru berhasil besar-besaran pada 2012 ketika tiga faktor bertemu bersamaan: data masif (internet), GPU yang cukup kuat dan murah, serta penyempurnaan teknik training.


Momen ledaknya: tahun 2012, tim Geoffrey Hinton memenangkan kompetisi ImageNet memakai model AlexNet, mengalahkan metode lain dengan selisih akurasi sangat besar. Tiga tokoh yang sering disebut “godfathers of deep learning” — Hinton, Yann LeCun, dan Yoshua Bengio — menerima Turing Award tahun 2018.

1.6 Kenapa “Attention Is All You Need” Disebut Fondasi Teknis

Makalah tahun 2017 oleh tim peneliti Google memperkenalkan arsitektur **Transformer**. Sebelumnya, model bahasa memproses teks berurutan kata-demi-kata (RNN/LSTM) — lambat dilatih dan sering “lupa” konteks kata yang jauh di awal kalimat panjang. **Inovasi kunci:** mekanisme “self-attention” — cara model melihat semua kata sekaligus dan menghitung relevansi tiap kata terhadap kata lainnya.

Kesimpulannya: semua LLM yang kita bahas — GPT, Claude, Gemini, Grok, Llama — dibangun di atas arsitektur Transformer ini (atau variasinya).

1.7 Pola Visual: Symbolic AI vs Connectionist AI



Kiri: Symbolic AI mengalir searah lewat aturan eksplisit (IF-THEN) yang ditulis manusia. Kanan: Connectionist AI (neural network) terdiri dari node-node yang saling terhubung, di mana kekuatan tiap koneksi (bobot) disesuaikan otomatis lewat training — inilah dasar logika LLM modern seperti Claude.

1.8 Studi Kasus Mudah: Symbolic AI vs Connectionist AI

Skenario: membangun sistem yang otomatis menandai email masuk sebagai “SPAM” atau “BUKAN SPAM”.

Pendekatan 1 — Symbolic AI (menulis aturan manual): programmer menulis aturan eksplisit — IF email mengandung kata “gratis”/“menang hadiah”/“klik di sini” THEN SPAM. Ini bekerja baik, sampai pengirim spam menulis “GR4T1S!!” untuk menghindari deteksi — sistem langsung kebobolan karena hanya mencocokkan kata persis, tidak benar-benar “mengerti” kata yang disamarkan.

Pendekatan 2 — Connectionist AI (belajar dari contoh): 10.000 email berlabel diserahkan ke jaringan saraf tiruan tanpa aturan ditulis manual. Sistem menemukan sendiri rumus: **Skor = $(0.7 \times \text{jumlah kata promosi}) + (0.5 \times \text{jumlah tautan aneh})$, jika Skor > 1.0 → SPAM.** Angka 0.7 dan 0.5 murni hasil sistem menyesuaikan diri lewat ribuan contoh — saat penipu menulis “GR4T1S”, sistem tetap bisa menangkapnya karena belajar pola umum, bukan kata persis.

Situasi	Symbolic AI	Connectionist AI
Email spam persis seperti contoh lama	Terdeteksi (sesuai aturan)	Terdeteksi (sesuai pola)
Spam dengan kata disamarkan (“GR4T1S”)	Lolos — butuh aturan baru ditulis manual	Biasanya tetap terdeteksi — mengenali pola umum
Menjelaskan kenapa email ditandai spam	Mudah — tinggal tunjuk aturan yang cocok	Sulit — bobot/pola tersebar di ribuan angka

Kesimpulan: Symbolic AI itu seperti murid yang menghafal contoh soal persis. Connectionist AI itu seperti murid yang benar-benar paham konsepnya — bisa menjawab soal yang sedikit diubah, tapi sering kesulitan menjelaskan logika persisnya. LLM seperti Claude adalah keturunan pendekatan Connectionist ini, dengan skala jutaan kali lebih besar.

BAB 2

Apa itu Machine Learning?

Definisi, sejarah, tiga jenis utama, alur kerja, dan studi kasus mudah

2.1 Definisi Formal & Sejarah Singkat

Machine learning pertama kali diistilahkan oleh Arthur Samuel pada 1959, peneliti IBM yang membuat program permainan dam (checkers) yang bisa memperbaiki caranya bermain sendiri setelah tiap partai — tanpa ia menulis ulang kodenya secara manual.


Definisi formal yang paling sering dikutip datang dari Tom Mitchell (1997): “Sebuah program dikatakan belajar dari pengalaman E terhadap tugas T dan ukuran performa P , jika performanya pada T (diukur dengan P) meningkat seiring bertambahnya E .” Sederhananya: makin banyak “pengalaman” (data) yang diberikan, makin baik performa sistem — tanpa manusia perlu menulis ulang aturannya.

2.2 Tiga Jenis Utama Machine Learning

Supervised Learning (belajar dengan label) — sistem diberi data yang sudah punya “kunci jawaban”. Studi kasus mudah: memprediksi harga rumah dari ribuan data (luas tanah, jumlah kamar) beserta harga jual sebenarnya. Deteksi spam di Bab 1 juga contoh supervised learning.


Unsupervised Learning (belajar tanpa label) — sistem hanya diberi data mentah tanpa “kunci jawaban”, dan harus menemukan pola/kelompok sendiri. Studi kasus mudah: toko online punya data belanja ribuan pelanggan tanpa kategori apa pun — sistem menemukan sendiri “kelompok pembeli hemat”, “kelompok pembeli impulsif”, dan “kelompok pembeli musiman”.

Reinforcement Learning (belajar lewat coba-coba) — analoginya paling mudah dari melatih anak anjing: setiap kali anjing duduk dengan benar, ia dapat camilan (reward). Ini persis cara AlphaGo (DeepMind, 2016) belajar main Go dengan bermain jutaan kali melawan dirinya sendiri.



Tiga jenis Machine Learning: titik biru/oranye pada Supervised menandakan data berlabel, titik hijau pada Unsupervised tidak berlabel, dan lingkaran oranye pada Reinforcement menggambarkan siklus agen–aksi–reward.

2.3 Alur Kerja Umum (Pipeline) Sebuah Proyek Machine Learning



Kumpulkan Data → Bersihkan & Siapkan Data → Bagi Data (Latih/Uji) → Latih Model → Uji & Evaluasi → jika belum akurat, kembali ke Latih Model; jika sudah baik, Deploy.

2.4 Istilah Kunci Tambahan

Istilah	Arti
Dataset	Kumpulan data yang dipakai untuk melatih/menguji model.
Fitur (feature)	Informasi/karakteristik yang dilihat model (mis. luas tanah, jumlah kata “gratis”).
Label	“Kunci jawaban” pada supervised learning.
Overfitting	Model terlalu hafal data latih sampai gagal saat menghadapi data baru.
Loss function	Cara mengukur “seberapa salah” tebakan model dibanding jawaban sebenarnya.
Gradient descent	Metode matematis untuk pelan-pelan mengurangi kesalahan dengan menyesuaikan bobot.

2.5 Studi Kasus: Bagaimana Bobot 0.7 dan 0.5 Ditemukan?

Ingat rumus di Bab 1: $\text{Skor} = (0.7 \times \text{kata promosi}) + (0.5 \times \text{tautan aneh})$. Bobot itu tidak ujug-ujug muncul — inilah **gradient descent** bekerja: sistem mulai dengan tebakan sembarangan (misal 0.1 dan 0.1), lalu mengecek 10.000 email latih satu per satu.

Setiap kali tebakannya salah (loss function mendeteksi kesalahan), sistem menyesuaikan sedikit bobotnya ke arah yang mengurangi kesalahan itu — diulang jutaan kali sampai bobotnya “settle” di angka paling akurat. Proses coba-perbaiki-coba lagi inilah **training**, dan ini juga persis proses yang melahirkan Claude — bedanya bukan cuma 2 bobot, tapi miliaran bobot yang disesuaikan lewat training raksasa.

BAB 3

Apa itu Large Language Model (LLM)?

Sejarah, dasar logika, proses training, dan studi kasus mudah

3.1 Sejarah Singkat: dari Model Bahasa Sederhana ke LLM


Model bahasa awalnya sangat sederhana — model n-gram, yang hanya menghitung “kata apa yang paling sering muncul setelah kata ini”. Lalu muncul RNN/LSTM (1990an–2010an) yang memproses kata berurutan tapi lambat dan gampang “lupa” konteks panjang.

Titik baliknya: Transformer (2017) memungkinkan model memproses seluruh kalimat sekaligus lewat self-attention. Dari situ lahir generasi LLM modern: GPT-1 dan BERT (2018), GPT-2 (2019) yang mulai menulis paragraf koheren, GPT-3 (2020) yang mengejutkan dunia dengan “few-shot learning”, lalu ChatGPT (November 2022) yang memopulerkan teknik RLHF. Anthropic lahir 2021 dari mantan peneliti OpenAI yang fokus membuat LLM lebih aman, melahirkan Claude.

3.2 Dasar Logika: Bagaimana LLM Sebenarnya “Menulis” Kalimat

LLM tidak “berpikir” jawaban lengkap sekaligus. Ia bekerja secara **autoregresif** — menebak satu token berikutnya, lalu token itu ditambahkan kembali ke input, lalu menebak lagi, diulang sampai jawaban selesai: (1) Tokenisasi, (2) Embedding, (3) Self-Attention, (4) distribusi probabilitas token berikutnya, (5) token dipilih (tergantung “temperature”), (6) token ditambahkan ke input, ulangi.

Proses Menghasilkan Satu Kata (Autoregressive)



Siklus autoregressive: setiap token baru yang dihasilkan ditambahkan kembali ke input, lalu proses diulang untuk menebak token berikutnya.

3.3 Studi Kasus Mudah: Melengkapi Kalimat “Kucing suka makan ____”

Bayangkan Anda mengetik “Kucing suka makan” ke Claude. Di balik layar, model menghitung distribusi probabilitas kira-kira begini: “ikan” 45%, “tikus” 20%, “daging” 15%, “rumpun” 2%. Model memilih “ikan” (paling mungkin), menambahkannya jadi “Kucing suka makan ikan”, lalu mengulang proses untuk menebak kata

berikutnya lagi.


Ini persis kenapa LLM kadang terasa “mengarang” hal yang salah (halusinasi) — ia tidak mengecek fakta, ia hanya memilih kata yang secara statistik paling masuk akal.

3.4 Bagaimana LLM Dilatih Jadi Asisten yang Membantu

LLM melewati dua tahap besar: **Pretraining** — model membaca triliunan kata dari internet/buku, hanya belajar menebak kata berikutnya. Hasilnya model yang pintar melanjutkan teks, tapi belum tentu “membantu”.

Fine-tuning dengan RLHF (Reinforcement Learning from Human Feedback) — manusia menilai berbagai jawaban model, dan model “dihadiah” untuk menghasilkan jawaban seperti itu. Inilah yang mengubah model dari sekadar “penyambung kalimat pintar” menjadi asisten seperti Claude.

Bagaimana LLM Dilatih (Training Pipeline)



Training pipeline LLM: Pretraining → Model Dasar → Fine-tuning RLHF → Model Asisten → Deployment.

3.5 Istilah Kunci Tambahan

Istilah	Arti
Autoregressive	Cara model menghasilkan teks satu token demi satu token.
Temperature	Pengaturan seberapa “berani”/acak model memilih kata.
RLHF	Reinforcement Learning from Human Feedback.
Prompt engineering	Teknik menyusun instruksi agar mendapat jawaban terbaik dari LLM.

Istilah	Arti
System prompt	Instruksi tersembunyi di awal percakapan yang mengatur perilaku model.

BAB 4

Training vs Inference

Kenapa model tidak “belajar saat itu juga”, dan studi kasus mudah

4.1 Kenapa Ini Perlu Dipisah Jadi Bagian Sendiri

Di Bab 2 dan 3 kita sudah menyinggung Training dan Inference sambil lalu. Bagian ini mengumpulkan keduanya jadi satu perbandingan utuh, karena banyak orang salah kira “ChatGPT/Claude belajar dari percakapan kita saat itu juga” — padahal keduanya adalah dua proses yang sangat berbeda dari segi biaya, waktu, dan kapan terjadinya.

4.2 Perbandingan Langsung

Aspek	Training	Inference
Kapan terjadi	Sekali (atau beberapa kali) sebelum model dirilis ke publik	Setiap kali pengguna mengirim pesan/pertanyaan
Berapa lama	Berbulan-bulan (membaca triliunan kata berulang kali)	Hitungan detik per respons
Biaya	Puluhan hingga ratusan juta dolar sekali proses	Sangat kecil per pesan, tapi berkali lipat kalau dikalikan jutaan pengguna
Apa yang berubah	Bobot/parameter model disesuaikan secara permanen	Tidak ada yang berubah permanen — model hanya “membaca” lalu dibuang
Apakah model “ingat” percakapan?	Tidak relevan — training sudah selesai sebelum kita chat	Hanya “ingat” dalam satu sesi (context window)

4.3 Studi Kasus Mudah: Restoran vs Koki

Bayangkan Training seperti proses seorang calon koki sekolah masak bertahun-tahun, mencicipi ribuan resep, dilatih banyak chef senior, sampai akhirnya benar-benar mahir. Proses ini mahal dan hanya terjadi sekali di awal karier.

Inference itu seperti koki yang sudah lulus, bekerja di restoran memasak pesanan pelanggan setiap hari. Koki tidak “sekolah lagi” dari nol — ia hanya memakai keahlian yang sudah dipelajari. Kalau resep pesannya aneh, koki bisa saja salah menebak cara memasaknya (mirip halusinasi LLM) — tapi ia tidak otomatis “belajar resep baru itu” untuk selamanya; keahliannya baru berubah kalau dikirim sekolah masak lagi (di-training ulang).

Inilah kenapa Claude tidak otomatis “mengingat” percakapan Anda kemarin ke sesi baru, dan kenapa knowledge cutoff hanya berubah lewat training ulang yang mahal, bukan dari obrolan sehari-hari.

BAB 5

Istilah Kunci (Glosarium Lengkap)

Rangkuman seluruh istilah kunci dari Bab 1–3, disusun jadi satu referensi

Rangkuman seluruh istilah yang sudah kita pelajari dari Bab 1 sampai 3, dikumpulkan jadi satu referensi supaya mudah dicari kapan pun Anda lupa artinya.

Istilah Dasar AI & Sejarah (Bab 1)

Istilah	Arti
Symbolic AI	Pendekatan AI berbasis aturan eksplisit (IF-THEN) yang ditulis manusia.
Connectionist AI	Pendekatan AI berbasis jaringan saraf tiruan yang belajar pola dari data.
Expert system	Sistem berbasis ribuan aturan eksplisit dari pakar manusia.
AI Winter	Periode dana & minat riset AI menurun drastis.
Deep learning	Neural network dengan banyak lapisan tersembunyi.
Transformer	Arsitektur (2017) berbasis self-attention; fondasi teknis semua LLM modern.

Istilah Machine Learning (Bab 2)

Istilah	Arti
Dataset	Kumpulan data untuk melatih/menguji model.
Fitur (feature)	Karakteristik yang dilihat model.
Label	“Kunci jawaban” pada supervised learning.
Supervised learning	Belajar dari data berlabel.
Unsupervised learning	Belajar dari data tanpa label; menemukan pola sendiri.
Reinforcement learning	Belajar lewat coba-coba dengan reward/hukuman.
Overfitting	Model terlalu hafal data latih, gagal pada data baru.
Loss function	Cara mengukur “seberapa salah” tebakan model.
Gradient descent	Metode menyesuaikan bobot pelan-pelan untuk mengurangi kesalahan.

Istilah LLM (Bab 3)

Istilah	Arti
Token	Potongan kecil teks; satuan hitung model.
Context window	Berapa banyak teks yang bisa “diingat” model sekaligus.

Istilah	Arti
Parameter	Angka internal penyimpan “pengetahuan” hasil training.
Autoregressive	Cara model menghasilkan teks satu token demi satu token.
Self-attention	Mekanisme model menghitung relevansi tiap kata terhadap kata lain.
Temperature	Pengaturan seberapa acak/kreatif model memilih kata.
Pretraining	Tahap awal model belajar menebak kata berikutnya.
RLHF	Fine-tuning memakai penilaian preferensi manusia.
Halusinasi	Jawaban AI yang terdengar meyakinkan tapi salah.
Knowledge cutoff	Batas tanggal pengetahuan bawaan model.
Prompt engineering	Teknik menyusun instruksi agar mendapat jawaban terbaik dari LLM.
System prompt	Instruksi tersembunyi di awal percakapan yang mengatur perilaku model.

BAB 6

Pemain Besar di Dunia AI

Filosofi, fokus, dan diferensiasi Anthropic, OpenAI, xAI, Google, dan Meta

Sekarang kita dalam filosofi dan fokus masing-masing perusahaan, karena ini menjelaskan kenapa Claude, ChatGPT, dan Grok terasa punya “kepribadian” berbeda meski sama-sama LLM.

6.1 Anthropic (Claude)

Didirikan 2021 oleh Dario dan Daniela Amodei, mantan petinggi riset OpenAI, bersama beberapa peneliti lain yang ingin fokus lebih besar pada keamanan AI (AI safety). Filosofi utamanya: “Constitutional AI” — melatih model mengikuti seperangkat prinsip eksplisit supaya perilakunya lebih bisa diprediksi dan aman.

6.2 OpenAI (ChatGPT)

Didirikan 2015, awalnya sebagai lembaga nirlaba riset AI, lalu berkembang jadi perusahaan yang merilis GPT dan ChatGPT (November 2022). Filosofinya condong ke kecepatan inovasi dan skala besar, mengejar kemampuan tertinggi (frontier capability).

6.3 xAI (Grok)

Didirikan 2023 oleh Elon Musk. Diferensiasi utamanya: integrasi erat dengan platform X (dulu Twitter), sehingga Grok punya akses ke percakapan/tren real-time.

6.4 Google (Gemini)

Dikembangkan oleh Google DeepMind (gabungan tim Google Brain dan DeepMind, yang sebelumnya juga membuat AlphaGo). Keunggulan utamanya: integrasi ekosistem Google dan riset multimodal yang sangat kuat.

6.5 Meta (Llama)

Berbeda dari yang lain, Meta merilis model Llama sebagai open-weight (bisa diunduh dan dijalankan sendiri), bukan hanya lewat API tertutup. Filosofinya: mempercepat riset AI global.

6.6 Studi Kasus Mudah: Kenapa Jawaban Bisa Berbeda?

Bayangkan Anda bertanya hal yang sama ke tiga asisten AI ini: “Apa pendapatmu soal topik kontroversial X?” Karena masing-masing dilatih dengan filosofi dan data yang sedikit berbeda, jawabannya bisa terasa berbeda nuansa — bukan karena salah satu “lebih pintar”, tapi karena prioritas desain yang berbeda saat masing-masing dilatih.

BAB 7

Ragam Model & Cara Memilih Model yang Tepat

Kenapa satu perusahaan punya banyak model, plus kerangka praktis memilihnya


7.1 Kenapa Satu Perusahaan Punya Banyak Model?

Setiap perusahaan AI membuat beberapa tingkatan (tier) model karena ada trade-off antara tiga hal: kepintaran, kecepatan, dan biaya. Model paling pintar biasanya paling mahal dan paling lambat, model paling cepat biasanya paling murah tapi kurang pintar untuk tugas sangat kompleks.

Kelas	Claude	ChatGPT	Grok	Cocok untuk
Kelas tertinggi	Claude Fable 5	GPT-5.6 Sol	Grok 4 Heavy	Riset, coding kompleks, analisis mendalam
Kelas menengah	Claude Opus / Sonnet	GPT-5.6 Terra / GPT-5.5	Grok 4.3 / 4.5	Kebutuhan sehari-hari yang cukup kompleks
Kelas ringan	Claude Haiku	GPT-5.6 Luna / mini-nano	Grok 4.1 Fast	Tugas ringan bervolume tinggi

7.2 Cara Memilih Model yang Tepat

Sebagai pengguna biasa, aplikasi biasanya sudah otomatis memakai model default yang seimbang. Tapi kalau Anda ingin memilih manual, kerangka sederhana berikut bisa jadi panduan cepat:



Alur keputusan sederhana: mulai dari kompleksitas tugas, lalu volume/kecepatan, baru jatuh ke pilihan default yang seimbang kalau keduanya tidak ekstrem.

7.3 Studi Kasus Mudah: Memilih Model untuk 3 Tugas Berbeda

Kebutuhan	Pilihan & Alasan
Menjawab 10.000 chat layanan pelanggan per hari (pertanyaan jam buka toko)	Model tercepat/termurah (mis. Haiku) — volume tinggi, tugas sederhana.
Menulis email harian, meringkas dokumen kerja	Model seimbang (mis. Sonnet) — cukup pintar, cepat, dan terjangkau.
Riset mendalam menganalisis 500 halaman laporan keuangan	Model kelas tertinggi (mis. Opus/Fable) — butuh penalaran berlapis.

BAB 8

Kesalahpahaman Umum tentang AI

Lima miskonsepsi paling umum, diluruskan dengan studi kasus mudah

Setelah memahami cara kerja AI dari Bab 1–7, sekarang kita luruskan beberapa kesalahpahaman umum yang paling sering membuat orang salah menilai kemampuan (atau bahaya) AI.

Kesalahpahaman 1: “AI itu sadar/punya perasaan”

Faktanya: LLM adalah sistem statistik yang memprediksi token berikutnya. Ia bisa menulis “Saya senang membantu Anda” bukan karena benar-benar merasakan senang, tapi karena pola kalimat semacam itu yang paling sesuai secara statistik. Studi kasus mudah: ini mirip aktor yang memerankan tokoh sedih di film — ucapannya terdengar tulus, tapi aktor itu sendiri tidak benar-benar sedih.

Kesalahpahaman 2: “AI selalu benar karena komputer tidak salah”

Faktanya: LLM bisa berhalusinasi — menghasilkan info yang terdengar meyakinkan tapi salah. Studi kasus mudah: seperti teman yang sangat pandai bicara tapi kadang menjawab dengan percaya diri padahal sebenarnya menebak — enak didengar, tapi tetap perlu dicek ulang untuk hal penting.

Kesalahpahaman 3: “AI belajar dari percakapan saya secara langsung”

Faktanya: seperti dibahas di Bab 4, model tidak berubah permanen hanya karena satu percakapan (inference tidak mengubah bobot model). Perubahan pengetahuan model hanya terjadi lewat training ulang yang mahal dan jarang dilakukan.

Kesalahpahaman 4: “Model yang lebih besar/mahal selalu lebih baik untuk semua tugas”

Faktanya: seperti dibahas di Bab 7, ada trade-off kepintaran vs kecepatan vs biaya. Model kelas tertinggi bisa jadi terlalu “berlebihan” dan lambat untuk tugas sederhana.

Kesalahpahaman 5: “AI itu netral dan objektif 100%”

Faktanya: karena LLM belajar dari data buatan manusia, ia juga bisa mewarisi bias yang ada dalam data tersebut. Bias dikurangi lewat RLHF dan pedoman keamanan, tapi tidak pernah bisa hilang 100%.

BAB 9

Langkah Praktis Terus Belajar

Lima kebiasaan praktis untuk menerapkan pemahaman AI sehari-hari, plus penutup

Ini bab penutup buku kita. Isinya bukan konsep baru, tapi langkah praktis supaya pemahaman dari Bab 1–8 benar-benar terpakai sehari-hari.

1. Coba Langsung, Jangan Cuma Baca Teori

Gunakan Claude/ChatGPT untuk tugas nyata: menulis email, meringkas dokumen, brainstorming ide. Perhatikan pola kapan jawabannya sangat membantu dan kapan meleset — ini melatih intuisi Anda soal batas kemampuan LLM jauh lebih efektif daripada hanya membaca penjelasan.

2. Selalu Verifikasi Fakta Penting

Karena LLM bisa berhalusinasi, untuk angka, tanggal, kutipan hukum, atau info medis, selalu cek ulang ke sumber terpercaya sebelum dipakai untuk keputusan penting.

3. Pilih Model Sesuai Kebutuhan, Bukan Selalu yang Termahal

Ingat kerangka dari Bab 7: tugas ringan dan berulang pakai model cepat/murah, tugas kompleks yang butuh penalaran dalam baru pakai model kelas tertinggi.

4. Latih Kemampuan Menulis Prompt yang Jelas

Instruksi yang spesifik (apa tujuannya, format yang diinginkan, batasan panjang) hampir selalu menghasilkan jawaban jauh lebih baik daripada pertanyaan yang samar.

5. Ikuti Perkembangan Secukupnya, Jangan FOMO

Dunia AI bergerak sangat cepat. Anda tidak perlu mengikuti setiap rilis model baru — cukup pahami konsep dasarnya dan perbarui pilihan alat setahun sekali atau saat kebutuhan berubah.

Penutup

Dengan menyelesaikan sembilan bab ini, Anda sekarang punya fondasi untuk memahami hampir semua percakapan seputar AI — dari “apa itu AI” sampai “kenapa ada banyak model dan cara memilihnya”. Kapan pun ada istilah atau perkembangan baru yang membingungkan, gunakan pola yang sama: cari definisinya, cari studi kasus sederhananya, lalu hubungkan ke salah satu bab yang sudah Anda kuasai.

Lampiran A — Perbandingan Model Claude

Fable, Opus, Sonnet, dan Haiku: keunggulan, kekurangan, dan deskripsi

Ringkasan keunggulan, kekurangan, dan deskripsi tiap model Claude, berdasarkan informasi resmi Anthropic, Juli 2026.

Model	Deskripsi	Keunggulan	Kekurangan
Claude Fable 5	Model kelas "Mythos" — tingkat kemampuan di atas Opus, dirancang untuk kerja agentic jangka panjang dan penalaran paling kompleks.	Performa tertinggi di keluarga Claude: coding jangka panjang, riset ilmiah, analisis keuangan, visi state-of-the-art, konteks 1 juta token.	Paling mahal (\$10/\$50 per juta token). Classifier keamanan cukup konservatif. Adaptive thinking tidak bisa dimatikan.
Claude Opus 4.8	Model andalan untuk coding agentic kompleks dan pekerjaan enterprise; pilihan default untuk sebagian besar kasus.	Penalaran, coding, dan kemampuan enterprise kuat; konteks 1 juta token; lebih murah dari Fable (\$5/\$25).	Di bawah Fable 5 dalam benchmark performa murni. Masih lebih mahal dibanding Sonnet/Haiku.
Claude Sonnet 5	Kombinasi terbaik antara kecepatan dan kecerdasan — titik tengah ideal untuk kebutuhan sehari-hari.	Seimbang performa & latensi, cukup cepat, harga terjangkau (\$3/\$15), konteks 1 juta token.	Tidak sekuat Opus/Fable untuk tugas penalaran paling berat atau agentic jangka sangat panjang.
Claude Haiku 4.5	Model tercepat dengan kecerdasan mendekati level frontier — cocok volume tinggi dan respons instan.	Latensi paling rendah, paling hemat biaya (\$1/\$5), tetap mendukung extended thinking.	Jendela konteks paling kecil (200k token), output maksimum lebih rendah, kurang cocok tugas sangat kompleks.

Catatan: semua model mendukung input teks dan gambar, kemampuan multibahasa, serta tersedia lewat Claude API, AWS Bedrock, Google Cloud, dan Microsoft Foundry.

TENTANG BUKU INI

Buku ini merangkum perjalanan belajar kecerdasan buatan (AI) dari nol — disusun bertahap dalam bahasa Indonesia yang sederhana, disertai studi kasus mudah di setiap bagian, supaya siapa pun (bahkan yang belum pernah menyentuh istilah AI) bisa benar-benar memahami cara kerja AI, machine learning, dan large language model (LLM) seperti Claude, ChatGPT, dan Grok.

Isi Buku

- 01** Apa itu AI (Kecerdasan Buatan)?
- 02** Apa itu Machine Learning?
- 03** Apa itu Large Language Model (LLM)?
- 04** Training vs Inference
- 05** Istilah Kunci (Glosarium)
- 06** Pemain Besar di Dunia AI
- 07** Ragam Model & Cara Memilih Model yang Tepat
- 08** Kesalahpahaman Umum tentang AI
- 09** Langkah Praktis Terus Belajar

“Semakin dalam Anda memahami cara kerja AI, semakin bijak Anda memakainya.”