

SERI BELAJAR AI · JILID 2

AI GENERATIF & LLM LANJUTAN

Dari Transformer sampai Batas Kemampuan AI



Membedah cara kerja ChatGPT, Claude, Gemini, Grok, dan LLaMA dari dalam — attention, training, embedding, RAG, fine-tuning, AI multimodal, hingga mengenali hallucination dan keterbatasannya.

SERI BELAJAR AI · JILID 2

Daftar Isi

Tahap 11 — Arsitektur Transformer & Attention Mechanism*Bagaimana AI Benar-Benar 'Membaca' dan Memahami Teks***Tahap 12 — Bagaimana LLM Dilatih: Next-Token Prediction & Training***Dari Teks Mentah sampai Menjadi Model yang Bisa Diajak Bicara***Tahap 13 — Embedding & Semantic Search***Mengubah Makna Kata Menjadi Angka yang Bisa Dihitung Komputer***Tahap 14 — RAG — Retrieval-Augmented Generation***AI yang 'Membuka Buku Catatan' Sebelum Menjawab***Tahap 15 — Fine-Tuning vs Prompting***Dua Cara Berbeda Menyesuaikan AI untuk Kebutuhan Spesifik Anda***Tahap 16 — AI Generatif Multimodal***Dari Teks ke Gambar, Audio, dan Video***Tahap 17 — Evaluasi, Hallucination & Keterbatasan LLM***Memahami Kapan dan Mengapa AI Bisa Salah*

Buku ini adalah kelanjutan Jilid 1 dalam seri Belajar AI. Setiap tahap membangun pemahaman dari fondasi arsitektur Transformer sampai keterbatasan AI generatif masa kini, dengan pembahasan yang selalu melibatkan beberapa model populer sekaligus — ChatGPT, Claude, Gemini, Grok, dan LLaMA — agar wawasan yang didapat tidak terpaku pada satu produk saja.

SERI BELAJAR AI · JILID 2 · TAHAP 11

Arsitektur Transformer & Attention Mechanism

Bagaimana AI Benar-Benar 'Membaca' dan Memahami Teks

Di Jilid 1 (Tahap 1 sampai 10), kita sudah belajar dasar-dasar AI: apa itu kecerdasan buatan, perbedaan pendekatan symbolic vs connectionist, cara kerja machine learning, neural network sederhana, sampai mengenal beberapa model AI besar yang ada saat ini seperti ChatGPT (OpenAI), Claude (Anthropic), Gemini (Google), Grok (xAI), dan LLaMA (Meta).

Sekarang kita masuk ke Jilid 2: AI Generatif & LLM Lanjutan. Tahap 11 ini adalah fondasi paling penting dalam seluruh jilid ini, karena hampir SEMUA chatbot AI modern yang Anda kenal — ChatGPT, Claude, Gemini, Grok, Copilot, LLaMA, Mistral, DeepSeek, dan lainnya — dibangun di atas satu arsitektur yang sama: Transformer, dengan jantungnya bernama attention mechanism.

Setelah memahami tahap ini, Anda akan tahu kenapa AI bisa menjawab pertanyaan panjang dengan tetap 'nyambung' ke konteks di awal kalimat, dan kenapa semua model besar sekarang punya cara kerja dasar yang mirip walaupun dibuat perusahaan berbeda-beda.

1. Masalah yang Ingin Dipecahkan

Sebelum tahun 2017, AI pemrosesan bahasa (menerjemahkan, merangkum, menjawab pertanyaan) umumnya memakai arsitektur bernama RNN atau LSTM. Cara kerjanya: AI membaca kalimat KATA DEMI KATA secara berurutan, sambil mencoba menyimpan 'ingatan' tentang kata-kata sebelumnya dalam sebuah memori yang terbatas.

Masalahnya ada dua. Pertama, prosesnya lambat karena harus dikerjakan satu per satu secara berurutan, tidak bisa disebar/diparalelkan ke banyak prosesor sekaligus. Kedua, dan ini yang lebih krusial, AI sering 'lupa' konteks penting dari awal kalimat kalau kalimatnya panjang — mirip memori jangka pendek yang penuh.

■ Analogi

Bayangkan Anda menerjemahkan surat panjang dengan cara membaca SATU kata, menerjemahkannya, lalu lanjut ke kata berikutnya sambil mengandalkan catatan kecil yang mudah penuh untuk mengingat konteks sebelumnya. Begitu suratnya panjang, Anda mulai salah paham konteks di bagian akhir karena 'catatan' Anda sudah kelebihan muatan. Inilah persis masalah yang dihadapi AI generasi sebelum Transformer.

2. Lahirnya Transformer: Baca Semua Kata Sekaligus

Pada tahun 2017, tim peneliti Google merilis makalah berjudul 'Attention Is All You Need', yang memperkenalkan arsitektur Transformer. Idennya radikal: daripada membaca kalimat kata demi kata secara berurutan, kenapa tidak membaca SEMUA kata sekaligus secara paralel, lalu membiarkan AI sendiri yang memutuskan kata mana yang paling penting untuk dipahami bersama kata lainnya?

Mekanisme yang memungkinkan AI 'memutuskan kata mana yang penting' inilah yang disebut attention mechanism — inti dari segala inovasi yang mengikutinya, termasuk seluruh keluarga model GPT (OpenAI/ChatGPT), Claude (Anthropic), Gemini (Google), Grok (xAI), dan LLaMA (Meta).

3. Attention Mechanism: Inti dari Segalanya

Attention adalah cara AI memberi 'bobot perhatian' berbeda-beda ke setiap kata lain dalam kalimat, tergantung seberapa relevan kata itu untuk memahami makna kata yang sedang diproses.

Contoh sederhana: perhatikan dua kalimat ini — 'Budi pergi ke bank untuk mengambil uang' dan 'Budi duduk di bank taman sambil membaca buku'. Kata 'bank' di kedua kalimat itu sama persis secara tulisan, tapi maknanya berbeda total. Manusia tahu bedanya karena secara otomatis 'memperhatikan' kata-kata di sekitarnya — 'uang' di kalimat pertama, 'taman' di kalimat kedua. Attention mechanism membuat AI melakukan hal yang sama: memberi bobot perhatian tinggi ke kata-kata kunci itu untuk menentukan makna yang tepat.

4. Cara Kerja Teknis: Query, Key, dan Value (QKV)

Secara teknis (disederhanakan), setiap kata diubah menjadi representasi angka (disebut vector/embedding), dan dari vector itu dibentuk tiga peran berbeda: Query (Q), Key (K), dan Value (V).

Query adalah 'pertanyaan' yang dibawa sebuah kata: 'informasi apa yang saya butuhkan dari kata-kata lain?' Key adalah semacam 'label' yang ditawarkan tiap kata lain: 'ini informasi yang saya punya.' Value adalah isi/informasi sebenarnya yang dibawa kata tersebut.

AI mencocokkan Query suatu kata dengan Key semua kata lain untuk menghasilkan skor relevansi. Skor ini diubah menjadi bobot perhatian (lewat fungsi matematika bernama softmax, yang membuat semua bobot berjumlah 100%). Bobot ini kemudian dikalikan dengan Value masing-masing kata dan dijumlahkan — hasilnya adalah representasi baru dari kata tersebut yang sudah 'membawa konteks' dari kata-kata lain yang relevan.

■ Analogi: Mencari Buku di Perpustakaan

Bayangkan Anda masuk perpustakaan membawa pertanyaan di kepala (Query): 'saya butuh resep nasi goreng'. Di setiap rak ada label (Key) yang menjelaskan isi rak itu. Anda mencocokkan pertanyaan Anda dengan label di setiap rak — rak 'Buku Masakan' cocok sekali, rak 'Novel Fiksi' tidak cocok. Semakin cocok label suatu rak dengan pertanyaan Anda, semakin besar perhatian yang Anda berikan ke rak itu, dan semakin banyak isi buku (Value) dari rak itu yang Anda pakai. Itulah persis cara kerja attention: mencocokkan 'apa yang dicari' dengan 'label yang tersedia', lalu mengambil 'isi' sesuai tingkat kecocokannya.

5. Self-Attention dan Multi-Head Attention

Disebut self-attention karena kata-kata dalam SATU kalimat yang sama saling 'memperhatikan' satu sama lain (bukan membandingkan dengan kalimat lain).

Dalam praktiknya, Transformer tidak menjalankan proses attention hanya sekali, tapi berkali-kali secara paralel dengan 'sudut pandang' berbeda-beda — ini disebut multi-head attention. Satu 'head' mungkin fokus menangkap hubungan subjek-predikat, head lain fokus menangkap hubungan kata yang berjauhan

letaknya, head lain lagi menangkap nada/emosi kalimat. Semua hasil dari head-head ini kemudian digabungkan menjadi satu pemahaman yang lebih kaya.

■ Analogi

Bayangkan satu kalimat dibaca bersamaan oleh beberapa ahli berbeda: satu ahli tata bahasa, satu ahli makna, satu ahli nada bicara. Masing-masing fokus ke aspek yang berbeda dari kalimat yang sama, lalu catatan mereka digabung jadi satu pemahaman utuh. Itulah multi-head attention.

6. Positional Encoding: Supaya AI Tahu Urutan Kata

Karena Transformer membaca semua kata SEKALIGUS (bukan satu-satu seperti RNN), ada risiko AI kehilangan informasi tentang urutan kata. Padahal urutan sangat menentukan makna: 'Budi memukul Andi' artinya sangat berbeda dengan 'Andi memukul Budi', walau kata-katanya persis sama.

Solusinya disebut positional encoding: semacam 'nomor urut' matematis yang ditambahkan ke representasi setiap kata, sehingga AI tetap tahu kata mana yang muncul lebih dulu, di tengah, atau di akhir kalimat — meski semua kata diproses secara paralel.

7. Dari Transformer ke LLM Modern: Decoder-Only

Transformer versi asli (2017) punya dua bagian: Encoder (bertugas memahami input) dan Decoder (bertugas menghasilkan output) — cocok untuk tugas seperti penerjemahan bahasa.

Namun hampir semua LLM (Large Language Model) populer saat ini — GPT di balik ChatGPT, Claude dari Anthropic, Gemini dari Google, Grok dari xAI, maupun LLaMA dari Meta — hanya memakai bagian Decoder saja, disebut arsitektur decoder-only. Model ini dilatih dengan tugas sederhana namun sangat kuat: memprediksi kata/token berikutnya, terus-menerus, satu per satu, berdasarkan semua kata sebelumnya. Mekanisme ini akan dibahas lebih dalam di Tahap 12.

Menariknya, walaupun ChatGPT, Claude, Gemini, Grok, dan LLaMA dibuat oleh perusahaan yang berbeda-beda dengan data dan cara pelatihan yang berbeda, fondasi arsitektur dasarnya — Transformer decoder-only dengan attention mechanism — pada dasarnya sama. Perbedaan performa dan karakter masing-masing model lebih banyak ditentukan oleh ukuran model, kualitas & jumlah data latih, serta teknik fine-tuning/alignment yang dipakai masing-masing perusahaan.

8. Mengapa Transformer Begitu Revolusioner

- Bisa diproses secara paralel (bukan satu per satu) → pelatihan jauh lebih cepat untuk data dalam jumlah sangat besar.
- Attention bisa langsung 'melompat' menghubungkan kata manapun dalam kalimat tanpa kehilangan konteks, walau kalimatnya panjang.
- Arsitektur yang sama bisa diperbesar (scale up) dengan menambah data dan parameter, menghasilkan lompatan kemampuan — inilah yang memicu lahirnya era LLM raksasa seperti sekarang.
- Karena fleksibel, arsitektur ini dipakai lintas perusahaan dan lintas jenis tugas: teks (ChatGPT, Claude, Gemini, Grok), gambar, audio, bahkan video generatif.


9. Studi Kasus Lengkap: Kalimat Ambigu

Perhatikan kalimat: 'Ani melihat burung di pohon dengan teropongnya.' Kalimat ini ambigu — siapa yang membawa teropong? Dua kemungkinan: (a) Ani melihat burung menggunakan teropong miliknya, atau (b) ada burung yang 'membawa' teropong (secara harfiah tidak masuk akal, tapi secara struktur kalimat bisa ditafsirkan begitu).


Saat memproses kalimat ini, mekanisme attention menghitung bobot hubungan antara kata 'teropongnya' dengan semua kata lain di kalimat. Karena model sudah dilatih dari jutaan contoh kalimat nyata, ia 'belajar' pola bahwa kata kerja 'melihat' dengan objek alat optik ('teropong') jauh lebih sering berkaitan dengan SUBJEK (orang yang melakukan aksi melihat) dibanding OBJEK yang dilihat (burung). Maka bobot attention antara 'teropongnya' dan 'Ani'/'melihat' akan jauh lebih besar dibanding bobot ke 'burung'.

Inilah sebabnya AI modern seperti ChatGPT, Claude, Gemini, atau Grok bisa menafsirkan kalimat ambigu dengan cukup akurat — bukan karena ia 'mengerti' seperti manusia, tapi karena attention mechanism-nya telah belajar pola hubungan antar-kata dari data pelatihan dalam jumlah sangat besar.

Diagram & Ilustrasi



Di dalam Attention: Query · Key · Value



Contoh: pada "Budi pergi ke bank untuk mengambil uang", kata 'uang' mendapat bobot perhatian tinggi terhadap 'bank', membantu model memilih makna 'bank deposit', bukan 'bank taman'.

Rangkuman Tahap 11

- Transformer (2017) memecahkan masalah AI generasi lama yang membaca kalimat kata demi kata dan mudah 'lupa' konteks panjang.
- Attention mechanism memungkinkan AI membaca semua kata sekaligus dan memberi bobot perhatian berbeda ke tiap kata, berdasarkan konsep Query-Key-Value.
- Multi-head attention menjalankan banyak 'sudut pandang' attention sekaligus; positional encoding menjaga informasi urutan kata.
- Hampir semua LLM populer saat ini — ChatGPT, Claude, Gemini, Grok, LLaMA, dan lainnya — memakai arsitektur Transformer decoder-only dengan fondasi attention yang sama, walau dibuat perusahaan berbeda.
- Tahap berikutnya (Tahap 12) akan membahas bagaimana LLM benar-benar 'dilatih' — next-token prediction, loss function, dan proses training dari awal hingga menjadi model yang bisa diajak bicara.

Istilah Penting

Transformer	Arsitektur neural network yang memproses seluruh urutan data (misalnya kalimat) secara paralel, memakai attention mechanism sebagai inti kerjanya. Diperkenalkan tahun 2017.
Attention Mechanism	Mekanisme yang memberi 'bobot perhatian' berbeda ke setiap bagian input, menentukan bagian mana yang paling relevan untuk dipahami bersama.
Self-Attention	Attention yang dihitung antar-kata dalam kalimat yang sama.
Multi-Head Attention	Menjalankan beberapa proses attention secara paralel dengan 'sudut pandang' berbeda-beda, lalu menggabungkan hasilnya.
Query, Key, Value (QKV)	Tiga representasi dari setiap kata yang dipakai untuk menghitung attention: Query = yang dicari, Key = label yang ditawarkan, Value = isi informasi.
Positional Encoding	Informasi tambahan yang disisipkan ke representasi kata agar AI tetap tahu urutan kata, walau semua kata diproses secara paralel.
Decoder-only	Jenis arsitektur Transformer yang hanya memakai bagian decoder, dilatih untuk memprediksi token berikutnya. Dipakai oleh GPT (ChatGPT), Claude, Gemini, Grok, LLaMA, dan sebagian besar LLM modern.
Softmax	Fungsi matematika yang mengubah sekumpulan skor menjadi bobot/probabilitas yang jumlahnya selalu 100%.

SERI BELAJAR AI · JILID 2 · TAHAP 12

Bagaimana LLM Dilatih: Next-Token Prediction & Training

Dari Teks Mentah sampai Menjadi Model yang Bisa Diajak Bicara

Di Tahap 11, kita belajar arsitektur Transformer dan attention mechanism — 'mesin' yang dipakai ChatGPT, Claude, Gemini, Grok, dan LLaMA untuk memproses teks. Tapi mesin itu, sebelum dilatih, hanyalah kumpulan angka acak yang tidak tahu apa-apa tentang bahasa.

Tahap 12 ini menjawab pertanyaan besar berikutnya: bagaimana caranya kumpulan angka acak itu bisa berubah menjadi model yang bisa menulis esai, menjawab pertanyaan, bahkan menulis kode program? Jawabannya ada pada proses training (pelatihan), yang intinya sangat sederhana walau dijalankan dalam skala sangat besar: menebak kata berikutnya, berulang kali, miliaran kali.

1. Tugas Sederhana di Balik Semua Kecerdasan: Next-Token Prediction

Inti pelatihan LLM (Large Language Model) ternyata sangat sederhana: model diberi potongan teks, lalu diminta menebak satu kata/token berikutnya. Itu saja. Model GPT di balik ChatGPT, Claude, Gemini, Grok, dan LLaMA semuanya dilatih dengan tugas dasar yang sama ini, hanya berbeda pada data, skala, dan detail teknik pelatihan masing-masing perusahaan.

Misalnya, model diberi teks 'Ibu kota Indonesia adalah', lalu diminta menebak kata berikutnya. Di awal pelatihan (saat bobot/weight modelnya masih acak), tebakannya akan sangat buruk — bisa jadi menebak kata acak yang tidak nyambung sama sekali. Tapi setelah dikoreksi jutaan-miliaran kali, model mulai belajar pola bahasa, fakta dunia, bahkan cara bernalar sederhana — semua muncul sebagai 'efek samping' dari tugas menebak kata berikutnya yang dilakukan dalam skala sangat besar.

■ Analogi

Bayangkan permainan tebak kata: teman Anda membacakan awal kalimat lalu berhenti, dan Anda harus menebak kata selanjutnya. Mula-mula tebakan Anda ngawur. Tapi setelah bermain ribuan kali dengan banyak kalimat berbeda, Anda mulai menangkap pola — tata bahasa, kebiasaan susunan kata, bahkan fakta umum (karena kalimat 'Ibu kota Indonesia adalah ____' hampir selalu diikuti 'Jakarta'). LLM belajar dengan cara yang serupa, hanya dengan skala data dan pengulangan yang jauh lebih besar daripada yang bisa dilakukan manusia.

2. Loss Function: Cara Model Tahu Dia Salah

Supaya model bisa 'belajar dari kesalahan', dibutuhkan cara untuk mengukur seberapa jauh tebakannya dari jawaban yang benar. Ukuran ini disebut loss function (fungsi kerugian/kesalahan).

Setiap kali model menebak token berikutnya, hasil tebakannya (berupa daftar probabilitas untuk setiap kemungkinan token) dibandingkan dengan token yang SEBENARNYA muncul di data latih. Semakin jauh tebakan dari jawaban sebenarnya, semakin besar nilai loss-nya. Tujuan pelatihan adalah membuat nilai loss ini sekecil mungkin, secara bertahap, lewat jutaan contoh.

3. Backpropagation: Cara Model Memperbaiki Diri

Setelah nilai loss dihitung, model perlu tahu bagian mana dari dirinya (dari miliaran parameter/bobot internal) yang harus disesuaikan, dan seberapa besar penyesuaiannya, agar tebakan berikutnya lebih baik. Proses ini disebut backpropagation, dipasangkan dengan teknik optimisasi (umumnya disebut gradient descent) yang menentukan arah dan besaran penyesuaian setiap bobot.

Proses ini diulang untuk SETIAP contoh teks dalam data latih, satu per satu (atau dalam kelompok kecil disebut batch), jutaan sampai miliaran kali. Setiap putaran, model menjadi sedikit lebih baik dalam menebak kata berikutnya.

■ Analogi

Bayangkan Anda belajar melempar panah ke papan target sambil ditutup matanya, hanya mendapat info 'terlalu ke kiri' atau 'terlalu ke kanan' setiap lemparan. Awalnya lemparan Anda berantakan, tapi dengan ribuan percobaan dan koreksi kecil setiap kali, tangan Anda perlahan 'terlatih' untuk melempar lebih akurat. Backpropagation adalah mekanisme matematis yang memberi tahu model 'koreksi' semacam itu untuk setiap bagian dirinya, setiap kali menebak salah.

4. Tiga Tahap Besar Melatih LLM Modern

- Pre-training: tahap pelatihan awal dan terbesar, model 'membaca' data teks dalam jumlah raksasa dari internet, buku, artikel, kode program, dan sumber lain, murni belajar menebak kata berikutnya. Tahap ini paling mahal secara komputasi dan memakan waktu berminggu-minggu bahkan berbulan-bulan dengan ribuan chip pemroses (GPU/TPU).
- Fine-tuning / Supervised Fine-Tuning (SFT): model hasil pre-training 'disempurnakan' dengan contoh percakapan berkualitas tinggi yang ditulis/dikurasi manusia, agar model belajar menjawab seperti asisten yang membantu, bukan sekadar menyambung teks.
- RLHF (Reinforcement Learning from Human Feedback) / alignment: manusia memberi penilaian terhadap berbagai jawaban model, dan model dilatih lebih lanjut untuk menghasilkan jawaban yang lebih disukai manusia — lebih aman, lebih membantu, lebih jujur. Setiap perusahaan (OpenAI untuk ChatGPT, Anthropic untuk Claude, Google untuk Gemini, xAI untuk Grok, Meta untuk LLaMA) punya pendekatan dan penekanan nilai yang sedikit berbeda di tahap ini, yang sebagian menjelaskan mengapa 'kepribadian' tiap model terasa berbeda walau fondasi arsitekturnya serupa.

5. Mengapa Butuh Data dan Komputasi Sebesar Itu

Model bahasa modern punya miliaran hingga triliunan parameter (bobot internal yang bisa disetel). Untuk menyetel parameter sebanyak itu secara bermakna, dibutuhkan data pelatihan dalam jumlah sangat besar (triliunan kata) dan daya komputasi masif (ribuan chip khusus AI yang bekerja selama berminggu-minggu).

Inilah salah satu alasan mengapa hanya segelintir perusahaan besar (OpenAI, Anthropic, Google, xAI, Meta, dan beberapa lainnya) yang mampu melatih model fondasi (foundation model) dari nol — biayanya bisa mencapai puluhan hingga ratusan juta dolar untuk satu model besar.

6. Studi Kasus: Dari Teks Acak ke Jawaban yang Masuk Akal

Bayangkan proses pelatihan dalam tiga 'snapshot' waktu. Di awal pelatihan (0% progres), jika diberi 'Resep membuat nasi goreng:', model mungkin menghasilkan teks acak tak bermakna karena bobotnya masih random. Di tengah pelatihan (pre-training sebagian selesai), model mulai menghasilkan kalimat yang tata bahasanya benar tapi isinya kadang tidak akurat atau tidak relevan. Setelah pre-training selesai dan melalui fine-tuning serta alignment, model mampu menghasilkan resep nasi goreng yang masuk akal, terstruktur, dan relevan dengan permintaan.


Perjalanan dari 'teks acak' ke 'jawaban yang membantu' inilah yang dilalui semua LLM besar saat ini, termasuk ChatGPT, Claude, Gemini, Grok, dan LLaMA — dengan detail data dan teknik alignment yang berbeda-beda di tiap perusahaan, menghasilkan karakter jawaban yang sedikit berbeda pula.

Diagram & Ilustrasi

Satu Putaran Training: Next-Token Prediction



Tiga Tahap Besar Melatih LLM Modern



Semua LLM populer (ChatGPT, Claude, Gemini, Grok, LLaMA) melalui pola 3 tahap ini — detail data & alignment berbeda per perusahaan.

Rangkuman Tahap 12

- Inti pelatihan LLM adalah tugas sederhana: menebak token/kata berikutnya, diulang dalam skala sangat besar.
- Loss function mengukur seberapa salah tebakan model; backpropagation menyesuaikan bobot internal model agar tebakan berikutnya lebih baik.
- Pelatihan LLM modern umumnya melalui tiga tahap besar: pre-training (belajar bahasa dari data raksasa), fine-tuning/SFT (belajar menjadi asisten), dan RLHF/alignment (belajar menjawab sesuai preferensi manusia).
- ChatGPT, Claude, Gemini, Grok, dan LLaMA semuanya melalui proses serupa, namun detail data dan teknik alignment masing-masing perusahaan berbeda — inilah salah satu sumber perbedaan 'karakter' tiap model.
- Tahap berikutnya (Tahap 13) akan membahas embedding — bagaimana makna kata direpresentasikan sebagai angka/vektor, fondasi dari semantic search dan RAG.

Istilah Penting

Next-Token Prediction	Tugas dasar pelatihan LLM: menebak token/kata berikutnya berdasarkan konteks sebelumnya.
Loss Function	Ukuran matematis seberapa jauh tebakan model dari jawaban yang benar; semakin kecil, semakin baik.
Backpropagation	Proses menghitung dan menyebarkan 'koreksi' ke seluruh parameter model agar tebakan berikutnya lebih akurat.
Pre-training	Tahap pelatihan awal dan terbesar, model belajar bahasa dari data teks dalam jumlah masif.
Fine-tuning / SFT	Penyempurnaan model hasil pre-training dengan contoh percakapan berkualitas tinggi agar menjadi asisten yang membantu.
RLHF	Reinforcement Learning from Human Feedback — melatih model lebih lanjut berdasarkan penilaian manusia terhadap kualitas jawaban.
Parameter	Bobot internal model yang disesuaikan selama pelatihan; model besar punya miliaran hingga triliunan parameter.

SERI BELAJAR AI · JILID 2 · TAHAP 13

Embedding & Semantic Search

Mengubah Makna Kata Menjadi Angka yang Bisa Dihitung Komputer

Di Tahap 11 kita sempat menyinggung 'embedding' sebagai langkah mengubah kata menjadi vektor angka sebelum masuk ke proses attention. Tahap 13 ini membahas konsep itu lebih dalam, karena embedding bukan cuma langkah teknis di Transformer — ia adalah fondasi dari banyak fitur AI modern: pencarian berbasis makna (semantic search), sistem rekomendasi, deteksi konten serupa, dan RAG (yang akan dibahas di Tahap 14).

Setelah tahap ini, Anda akan paham kenapa AI bisa tahu bahwa 'mobil' dan 'kendaraan' punya makna yang dekat, atau bahwa 'raja' dikurangi 'pria' ditambah 'wanita' kurang lebih menghasilkan 'ratu' — semua lewat operasi matematika sederhana pada angka.

1. Masalah: Komputer Hanya Mengerti Angka

Komputer tidak benar-benar 'memahami' kata seperti manusia. Supaya AI bisa memproses bahasa, setiap kata (atau potongan kata/token) harus diubah menjadi representasi angka. Cara paling sederhana adalah memberi setiap kata sebuah ID angka unik (misalnya 'kucing'=102, 'anjing'=305). Tapi cara ini punya masalah besar: angka 102 dan 305 tidak menunjukkan bahwa 'kucing' dan 'anjing' itu mirip (sama-sama hewan peliharaan), sementara 'kucing' dan 'meja' yang sama sekali tidak berhubungan mungkin kebetulan punya ID angka yang berdekatan.

2. Solusinya: Embedding — Kata sebagai Titik dalam Ruang Makna

Embedding adalah cara merepresentasikan setiap kata sebagai sebuah vektor — daftar angka (misalnya ratusan hingga ribuan angka desimal) — yang posisinya dalam 'ruang makna' berdimensi tinggi mencerminkan makna kata tersebut. Kata-kata dengan makna mirip akan punya vektor yang 'berdekatan' dalam ruang ini, sementara kata yang maknanya jauh berbeda akan punya vektor yang 'berjauhan'.

Vektor-vektor ini TIDAK diisi manual oleh manusia. Mereka dipelajari otomatis oleh model AI selama proses pelatihan (lihat Tahap 12), berdasarkan pola kata-kata yang sering muncul berdekatan dalam kalimat-kalimat nyata dari data pelatihan.

■ Analogi

Bayangkan sebuah peta raksasa di mana setiap kata punya satu titik koordinat. Kata 'kucing' dan 'anjing' ditempatkan berdekatan karena sering muncul dalam konteks serupa (hewan peliharaan, makan, bermain). Kata 'mobil' dan 'motor' juga berdekatan satu sama lain, tapi jauh dari 'kucing' dan 'anjing'. Kata 'bahagia' dan 'senang' saling berdekatan di area yang berbeda lagi (emosi). Peta ini tidak digambar manual — ia 'muncul dengan sendirinya' setelah model membaca miliaran kalimat dan belajar kata mana yang sering dipakai dalam konteks yang mirip.

3. Aritmatika Makna: Contoh Klasik King - Man + Woman = Queen

Salah satu penemuan paling terkenal dari embedding adalah bahwa hubungan antar-kata bisa direpresentasikan sebagai operasi matematika sederhana. Jika kita ambil vektor kata 'king' (raja), kurangi dengan vektor 'man' (pria), lalu tambahkan vektor 'woman' (wanita), hasilnya akan sangat dekat dengan vektor kata 'queen' (ratu) — walau tidak ada yang secara eksplisit memprogram hubungan ini. Pola ini 'muncul sendiri' dari cara model belajar dari data bahasa dalam jumlah besar.

Contoh serupa dalam Bahasa Indonesia: vektor 'Jakarta' dikurangi 'Indonesia' ditambah 'Jepang' cenderung menghasilkan vektor yang dekat dengan 'Tokyo' — karena pola hubungan 'ibu kota dari' tertangkap secara konsisten dalam ruang embedding.

4. Mengukur Kedekatan Makna: Cosine Similarity

Untuk mengetahui seberapa 'dekat' makna dua kata atau kalimat, AI menghitung sudut antara dua vektor tersebut dalam ruang berdimensi tinggi — disebut cosine similarity. Semakin kecil sudutnya (semakin searah dua vektor itu), semakin mirip maknanya; nilainya biasanya dinyatakan antara -1 (berlawanan makna) sampai 1 (identik maknanya).

Teknik ini tidak hanya berlaku untuk kata tunggal, tapi juga bisa diperluas untuk KALIMAT UTUH atau bahkan dokumen lengkap, dengan menghasilkan satu vektor yang mewakili makna keseluruhan teks tersebut — inilah dasar dari semantic search.

5. Semantic Search: Mencari Berdasarkan Makna, Bukan Kata Persis

Mesin pencari tradisional (seperti pencarian kata kunci biasa) hanya mencocokkan kata-kata yang PERSIS SAMA. Semantic search berbeda: ia mengubah query pencarian dan semua dokumen yang dicari menjadi vektor embedding, lalu mencari dokumen dengan vektor PALING MIRIP, meski kata-katanya tidak identik.


Contoh: jika Anda mencari 'cara membuat kendaraan roda dua tidak berisik', semantic search bisa menemukan dokumen berjudul 'tips mengurangi suara knalpot motor', meski tidak ada satu kata pun yang sama persis — karena secara MAKNA, kedua kalimat itu sangat berkaitan.

■ Analogi

Bayangkan pustakawan yang sangat paham isi semua buku di perpustakaan (bukan sekadar hafal judul). Saat Anda bertanya 'buku tentang hewan buas yang hidup berkelompok di savana', pustakawan ini bisa langsung menyodorkan buku berjudul 'Singa: Raja Padang Rumput Afrika', meski tidak ada kata yang sama persis antara pertanyaan Anda dan judul bukunya — karena ia memahami MAKNA, bukan sekadar mencocokkan kata.


Diagram & Ilustrasi

Ruang Makna (Embedding Space) Kata Bermakna Mirip → Posisi Berdekatan



Posisi hanya ilustrasi — ruang makna asli berdimensi ratusan/ribuan

Aritmatika Makna king – man + woman ≈ queen



Hubungan antar-kata 'muncul sendiri' dalam ruang embedding — tidak diprogram manual, tapi dipelajari dari pola miliaran kalimat nyata.

Rangkuman Tahap 13

- Embedding mengubah kata (atau kalimat/dokumen) menjadi vektor angka yang posisinya dalam 'ruang makna' mencerminkan makna sebenarnya — kata bermakna mirip punya vektor berdekatan.
- Vektor ini dipelajari otomatis oleh model dari data, bukan diprogram manual; hubungan antar-kata bahkan bisa diotak-atik lewat operasi matematika sederhana ($\text{king} - \text{man} + \text{woman} \approx \text{queen}$).
- Cosine similarity dipakai untuk mengukur seberapa dekat makna dua vektor.
- Semantic search memakai embedding untuk mencari berdasarkan MAKNA, bukan hanya kecocokan kata persis — inilah fondasi penting untuk Tahap 14: RAG (Retrieval-Augmented Generation).

Istilah Penting

Embedding	Representasi kata/kalimat/dokumen sebagai vektor angka yang mencerminkan maknanya dalam ruang berdimensi tinggi.
Vector Space (Ruang Vektor)	Ruang matematis berdimensi tinggi tempat semua vektor embedding 'ditempatkan' berdasarkan makna.
Cosine Similarity	Ukuran kedekatan makna antar dua vektor, berdasarkan sudut di antara keduanya.
Semantic Search	Pencarian berbasis makna (bukan hanya kecocokan kata persis), memanfaatkan kedekatan vektor embedding.
Nearest Neighbor Search	Teknik mencari vektor-vektor yang paling dekat/mirip dengan vektor query dalam suatu kumpulan data besar.

SERI BELAJAR AI · JILID 2 · TAHAP 14

RAG — Retrieval-Augmented Generation

AI yang 'Membuka Buku Catatan' Sebelum Menjawab

LLM seperti ChatGPT, Claude, Gemini, Grok, atau LLaMA hanya 'tahu' apa yang ada dalam data pelatihannya, yang punya batas waktu tertentu (knowledge cutoff) dan tidak mencakup dokumen pribadi Anda — seperti kebijakan internal perusahaan, laporan keuangan terbaru, atau isi email Anda. Lalu bagaimana AI bisa menjawab pertanyaan tentang dokumen yang belum pernah dilihatnya sebelumnya, atau peristiwa yang terjadi SETELAH data pelatihannya berakhir?

Jawabannya: RAG (Retrieval-Augmented Generation) — teknik yang menggabungkan embedding dan semantic search (Tahap 13) dengan kemampuan generatif LLM (Tahap 11-12), sehingga AI bisa 'membuka buku catatan' yang relevan terlebih dahulu sebelum menjawab, alih-alih hanya mengandalkan 'ingatan' dari data pelatihan.

1. Masalah yang Dipecahkan RAG

- Knowledge cutoff: LLM tidak tahu peristiwa yang terjadi setelah data pelatihannya berhenti dikumpulkan.
- Data privat/internal: LLM tidak pernah membaca dokumen pribadi Anda (kontrak perusahaan, database pelanggan, manual produk internal) kecuali diberi tahu secara eksplisit.
- Hallucination (mengarang jawaban): tanpa sumber yang jelas, LLM kadang 'mengarang' jawaban yang terdengar meyakinkan tapi salah (akan dibahas lebih dalam di Tahap 17).

2. Cara Kerja RAG, Langkah demi Langkah

Langkah 1 — Indexing (dilakukan sekali di awal, sebelum ada pertanyaan): dokumen-dokumen sumber (PDF, halaman web, database) dipecah menjadi potongan-potongan kecil (chunks), lalu masing-masing potongan diubah menjadi vektor embedding dan disimpan dalam basis data khusus bernama vector database.

Langkah 2 — Retrieval (saat ada pertanyaan dari pengguna): pertanyaan pengguna juga diubah menjadi vektor embedding, lalu dicari potongan dokumen dengan vektor PALING MIRIP di vector database (persis teknik semantic search dari Tahap 13).

Langkah 3 — Augmentation: potongan-potongan dokumen paling relevan yang ditemukan tadi 'disisipkan' ke dalam prompt yang dikirim ke LLM, sebagai konteks tambahan.

Langkah 4 — Generation: LLM (GPT, Claude, Gemini, Grok, atau model lain) menghasilkan jawaban berdasarkan PERTANYAAN pengguna DITAMBAH potongan dokumen relevan yang baru saja ditemukan — bukan hanya mengandalkan 'ingatan' dari pelatihan.

3. Studi Kasus: Chatbot Internal Perusahaan

Bayangkan sebuah perusahaan ingin membuat chatbot yang bisa menjawab pertanyaan karyawan tentang kebijakan cuti terbaru, yang baru diperbarui minggu lalu dan tentu saja TIDAK ada dalam data pelatihan LLM manapun.

Dengan RAG: dokumen kebijakan cuti terbaru diindex ke vector database. Saat karyawan bertanya 'berapa hari cuti melahirkan yang saya dapat?', sistem mencari potongan dokumen kebijakan yang paling relevan dengan pertanyaan itu, menyisipkannya ke prompt, lalu LLM menjawab berdasarkan isi dokumen tersebut — bukan menebak-nebak dari pengetahuan umum yang mungkin sudah usang atau salah.

■ Analogi

Bayangkan seorang asisten yang sangat pintar tapi baru bekerja dan belum hafal semua aturan perusahaan. Alih-alih menjawab dari ingatan yang mungkin salah/usang, asisten ini punya kebiasaan baik: setiap kali ditanya, ia dulu membuka buku pedoman perusahaan, mencari halaman yang relevan dengan pertanyaan itu, membacanya sekilas, BARU menjawab berdasarkan apa yang baru dibacanya. Itulah persis yang dilakukan RAG — 'membuka buku catatan' sebelum menjawab, alih-alih menjawab murni dari ingatan.

4. Mengapa RAG Penting dan Populer


- Jawaban lebih akurat dan bisa diberi sumber/rujukan (bisa ditunjukkan dokumen mana yang jadi dasar jawaban).
- Tidak perlu melatih ulang (fine-tuning) model yang mahal setiap kali ada dokumen baru — cukup tambahkan dokumen baru ke vector database.
- Bisa dipakai untuk data yang sangat privat/internal tanpa harus mengirim data itu untuk melatih ulang model AI pihak ketiga.
- Banyak produk AI populer memakai pendekatan ini, termasuk fitur 'chat dengan dokumen Anda' di berbagai platform AI, serta fitur pencarian berbasis AI di aplikasi seperti Notion AI, Microsoft Copilot, maupun fitur upload-dokumen di ChatGPT, Claude, dan Gemini.

5. RAG vs Fine-Tuning: Kapan Pakai yang Mana?


RAG cocok ketika informasi sering berubah (kebijakan, berita, dokumen internal yang terus diperbarui) dan Anda ingin jawaban bisa ditelusuri sumbernya. Fine-tuning (akan dibahas lebih detail di Tahap 15) lebih cocok ketika Anda ingin mengubah GAYA atau PERILAKU model secara mendasar, bukan sekadar menambah pengetahuan faktual baru. Dalam praktiknya, banyak sistem AI canggih menggabungkan keduanya.

Diagram & Ilustrasi

Langkah 1: Indexing (dilakukan sekali di awal)



Langkah 2-4: Saat Ada Pertanyaan Pengguna



Rangkuman Tahap 14

- RAG (Retrieval-Augmented Generation) memungkinkan LLM menjawab berdasarkan dokumen eksternal/terbaru, bukan hanya dari data pelatihan yang sudah 'membeku' di suatu waktu.
- Cara kerjanya: indexing dokumen jadi vector database → saat ada pertanyaan, cari potongan dokumen relevan (retrieval) → sisipkan ke prompt (augmentation) → LLM menjawab berdasarkan itu (generation).
- RAG memanfaatkan langsung konsep embedding dan semantic search dari Tahap 13.
- RAG membantu mengurangi hallucination dan memungkinkan jawaban yang bisa ditelusuri sumbernya, serta dipakai luas di produk AI modern.
- Tahap berikutnya (Tahap 15) membahas Fine-Tuning vs Prompting — dua cara lain menyesuaikan perilaku LLM untuk kebutuhan spesifik.

Istilah Penting

RAG (Retrieval-Augmented Generation)	Teknik yang menggabungkan pencarian dokumen relevan (retrieval) dengan kemampuan menjawab LLM (generation).
Vector Database	Basis data khusus yang menyimpan potongan dokumen dalam bentuk vektor embedding agar bisa dicari berdasarkan kemiripan makna.
Chunking	Proses memecah dokumen panjang menjadi potongan-potongan kecil sebelum diubah menjadi embedding.
Retrieval	Langkah mencari potongan dokumen paling relevan dengan pertanyaan pengguna.
Knowledge Cutoff	Batas waktu data pelatihan sebuah LLM; model tidak tahu peristiwa setelah tanggal ini kecuali diberi informasi tambahan (misalnya lewat RAG).

SERI BELAJAR AI · JILID 2 · TAHAP 15

Fine-Tuning vs Prompting

Dua Cara Berbeda Menyesuaikan AI untuk Kebutuhan Spesifik Anda

Setelah memahami bagaimana LLM dilatih (Tahap 12) dan bagaimana RAG memberinya akses ke dokumen eksternal (Tahap 14), muncul pertanyaan praktis: bagaimana jika saya ingin AI berperilaku dengan cara tertentu — misalnya selalu menjawab dengan gaya formal, atau sangat ahli dalam istilah hukum perusahaan saya? Ada dua pendekatan utama: prompting (termasuk in-context learning) dan fine-tuning. Tahap 15 ini membahas keduanya, kapan masing-masing cocok dipakai, dan bagaimana keduanya saling melengkapi.

1. Prompting: Mengarahkan AI Lewat Instruksi, Tanpa Melatih Ulang

Prompting adalah cara paling sederhana dan paling umum dipakai sehari-hari: memberi instruksi, konteks, atau contoh langsung dalam percakapan dengan AI, TANPA mengubah satu pun bobot/parameter internal model. Model dasar (seperti GPT di balik ChatGPT, atau model dasar Claude/Gemini/Grok/LLaMA) tetap sama persis; yang berubah hanyalah teks yang kita berikan sebagai instruksi.

Salah satu bentuk prompting yang kuat disebut in-context learning (atau few-shot prompting): kita memberi beberapa CONTOH di dalam prompt tentang bagaimana kita ingin AI menjawab, dan model akan 'meniru' pola dari contoh-contoh itu untuk pertanyaan baru, meski tidak pernah 'dilatih ulang' secara formal.

■ Analogi

Prompting ibarat memberi instruksi lisan kepada seorang pegawai baru yang sebenarnya sudah sangat berpengalaman dan pintar: 'tolong tulis balasan email ini dengan nada formal, dan sertakan tiga poin utama berikut.' Pegawai itu TIDAK perlu 'belajar ulang' keahliannya dari nol — ia hanya menyesuaikan caranya bekerja berdasarkan instruksi spesifik yang baru saja diberikan, lalu kembali ke 'default' di percakapan berikutnya.

2. Fine-Tuning: Melatih Ulang Sebagian Model untuk Tugas Spesifik

Fine-tuning adalah proses melanjutkan pelatihan model yang SUDAH ADA (model dasar hasil pre-training) dengan data tambahan yang lebih spesifik, sehingga bobot/parameter internal model BENAR-BENAR BERUBAH (walau biasanya hanya sebagian kecil darinya yang disesuaikan, tergantung tekniknya).

Berbeda dengan prompting yang sifatnya sementara (hanya berlaku untuk percakapan itu), hasil fine-tuning menjadi 'melekat' secara permanen pada model baru itu — model akan konsisten berperilaku sesuai data fine-tuning, bahkan tanpa instruksi khusus di setiap prompt.

■ Analogi

Fine-tuning ibarat mengirim pegawai itu mengikuti PELATIHAN KHUSUS selama berminggu-minggu untuk menjadi ahli di bidang sangat spesifik — misalnya terminologi hukum perusahaan farmasi. Setelah pelatihan itu, keahliannya benar-benar 'melekat' pada dirinya; ia akan otomatis memakai istilah dan gaya yang tepat tanpa perlu diingatkan setiap kali, karena caranya berpikir sudah benar-benar berubah, bukan sekadar mengikuti instruksi sesaat.

3. Perbandingan Langsung

Aspek	Prompting / In-Context Learning	Fine-Tuning
Mengubah bobot model?	Tidak	Ya (sebagian atau seluruhnya)
Biaya & waktu	Sangat murah & instan	Butuh data latih, komputasi, dan waktu
Sifat perubahan	Sementara, per-percakapan	Permanen, melekat pada model baru
Cocok untuk	Instruksi gaya, format jawaban, tugas umum	Pengetahuan/gaya sangat spesifik & konsisten, istilah khusus domain
Butuh data latih khusus?	Tidak wajib (cukup contoh di prompt)	Ya, perlu dataset contoh berkualitas

4. Parameter-Efficient Fine-Tuning (PEFT) & LoRA


Melakukan fine-tuning penuh terhadap model raksasa (dengan miliaran parameter) sangat mahal secara komputasi. Karena itu, berkembang teknik yang lebih hemat bernama PEFT (Parameter-Efficient Fine-Tuning), dengan metode populer bernama LoRA (Low-Rank Adaptation). Alih-alih mengubah SEMUA bobot model, LoRA hanya menambahkan sejumlah kecil parameter baru yang dilatih, sementara mayoritas bobot model asli dibiarkan tidak berubah — hasilnya jauh lebih murah dan cepat, namun tetap efektif untuk banyak kasus penggunaan.

5. Kapan Memilih yang Mana?

- Butuh AI mengikuti format/gaya tertentu untuk tugas sesekali? Cukup prompting — paling cepat dan murah.
- Butuh AI mengakses informasi terbaru/dokumen spesifik yang sering berubah? Pakai RAG (Tahap 14), bukan fine-tuning.
- Butuh AI punya 'kepribadian'/keahlian sangat konsisten dalam domain sangat spesifik (misalnya istilah medis, gaya penulisan khas brand tertentu) untuk dipakai berulang kali dalam skala besar? Fine-tuning lebih masuk akal, meski biayanya lebih besar.
- Dalam praktiknya, banyak aplikasi AI menggabungkan ketiganya: model dasar (dari OpenAI, Anthropic, Google, xAI, atau Meta) + fine-tuning ringan (opsional) + prompting yang baik + RAG untuk data terbaru.

Diagram & Ilustrasi

Dua Jalan Menyesuaikan AI untuk Kebutuhan Spesifik



Butuh data yang sering berubah? → Lihat RAG (Tahap 14), bukan fine-tuning.

Rangkuman Tahap 15

- Prompting mengarahkan perilaku AI lewat instruksi dalam percakapan, TANPA mengubah model — cepat, murah, tapi sifatnya sementara.
- Fine-tuning benar-benar mengubah sebagian bobot internal model lewat pelatihan tambahan — lebih mahal, tapi hasilnya melekat permanen pada model baru.
- Teknik seperti LoRA/PEFT membuat fine-tuning jauh lebih hemat biaya dengan hanya melatih sebagian kecil parameter tambahan.
- Pilihan antara prompting, RAG, dan fine-tuning tergantung kebutuhan: instruksi sesaat, data yang sering berubah, atau keahlian/gaya yang harus konsisten permanen.
- Tahap berikutnya (Tahap 16) membahas AI generatif multimodal — bagaimana AI menghasilkan gambar, audio, dan video, bukan hanya teks.

Istilah Penting

Prompting	Mengarahkan perilaku AI lewat instruksi/contoh dalam teks percakapan, tanpa mengubah model.
In-Context Learning	Kemampuan model 'meniru' pola dari contoh yang diberikan langsung di dalam prompt.
Fine-Tuning	Melanjutkan pelatihan model yang sudah ada dengan data tambahan spesifik, mengubah sebagian bobot internalnya.
LoRA (Low-Rank Adaptation)	Teknik fine-tuning hemat biaya yang hanya menambah & melatih sebagian kecil parameter baru, bukan seluruh model.
PEFT	Parameter-Efficient Fine-Tuning — kelompok teknik fine-tuning yang hemat komputasi, salah satunya LoRA.

SERI BELAJAR AI · JILID 2 · TAHAP 16

AI Generatif Multimodal

Dari Teks ke Gambar, Audio, dan Video

Sejauh ini, Tahap 11-15 fokus pada AI yang bekerja dengan TEKS. Tapi dunia AI generatif jauh lebih luas: ada AI yang bisa membuat gambar dari deskripsi teks (seperti Midjourney, DALL-E, Stable Diffusion, atau fitur gambar di Gemini dan GPT-4o), AI yang membuat suara/musik (seperti Suno atau ElevenLabs), bahkan AI yang membuat video penuh dari teks (seperti Sora dari OpenAI, Veo dari Google, atau Runway). Tahap 16 membahas bagaimana cara kerja AI 'lintas-media' ini secara umum, dan bagaimana ia berhubungan dengan konsep-konsep yang sudah kita pelajari di tahap sebelumnya.

1. Apa Itu 'Multimodal'?

Multimodal berarti AI yang bisa memproses dan/atau menghasilkan lebih dari satu jenis data (modalitas) — teks, gambar, audio, video. Ada dua arah: (a) AI yang bisa MEMAHAMI input dari berbagai modalitas (misalnya Claude, Gemini, dan GPT-4o yang bisa 'melihat' gambar yang Anda unggah dan menjelaskannya), dan (b) AI yang bisa MENGHASILKAN (generate) konten dalam modalitas yang berbeda dari inputnya, misalnya mengubah teks deskripsi menjadi gambar.

Tahap ini fokus terutama pada kemampuan GENERATIF lintas-modalitas: bagaimana AI mengubah deskripsi teks menjadi gambar, audio, atau video yang benar-benar baru.

2. Cara Kerja Umum: Mengubah Teks Menjadi Gambar

Mayoritas AI generator gambar populer saat ini (termasuk Stable Diffusion, Midjourney, dan DALL-E) memakai pendekatan bernama diffusion model. Cara kerjanya cukup unik dan berlawanan dengan intuisi: model dilatih untuk 'membersihkan noise' (derau/bintik acak) secara bertahap dari sebuah gambar, langkah demi langkah, sampai menghasilkan gambar yang jelas dan sesuai dengan deskripsi teks yang diberikan.

Saat menghasilkan gambar baru, prosesnya dimulai dari gambar yang BENAR-BENAR hanya berisi noise acak (seperti gambar 'semut' di TV lama), lalu model secara bertahap 'membersihkan' noise itu sedikit demi sedikit (puluhan langkah), setiap kali dipandu oleh embedding (ingat Tahap 13!) dari deskripsi teks yang kita berikan, sampai akhirnya noise acak itu 'berubah' menjadi gambar yang koheren dan sesuai deskripsi.

■ Analogi

Bayangkan seorang pematung yang bekerja dengan cara terbalik dari biasanya: ia mulai dari balok marmer yang terlihat seperti 'kekacauan' tanpa bentuk, lalu secara bertahap memahat sedikit demi sedikit, SAMBIL terus melihat sketsa/deskripsi yang Anda berikan sebagai panduan, sampai akhirnya bentuk yang jelas muncul dari kekacauan tadi. Diffusion model bekerja mirip seperti ini — 'memahat' gambar dari noise acak, bertahap, dipandu deskripsi teks.

3. Bagaimana dengan Audio dan Video?

AI generator audio (musik maupun suara/voice) umumnya juga memakai pendekatan serupa (diffusion atau varian arsitektur Transformer yang disesuaikan untuk data audio), hanya saja 'kanvas'-nya bukan piksel gambar, melainkan gelombang suara atau representasi spektral audio.

AI generator video (seperti Sora dari OpenAI atau Veo dari Google) jauh lebih kompleks karena harus menjaga KONSISTENSI antar-frame dari waktu ke waktu (objek, pencahayaan, gerakan harus masuk akal dan konsisten dari satu frame ke frame berikutnya), biasanya menggabungkan prinsip diffusion dengan arsitektur Transformer untuk menangani dimensi waktu (temporal) selain dimensi ruang (spasial).

4. Peran Embedding Lintas-Modalitas (CLIP dan Sejenisnya)


Agar AI bisa menghubungkan deskripsi TEKS dengan GAMBAR yang sesuai, dibutuhkan 'jembatan' yang menempatkan teks dan gambar dalam ruang embedding YANG SAMA (ingat konsep embedding dari Tahap 13) — sehingga teks 'kucing oranye duduk di jendela' punya vektor yang dekat dengan foto-foto kucing oranye yang sedang duduk di jendela. Model seperti CLIP (dikembangkan OpenAI) adalah contoh terkenal dari pendekatan ini, dan menjadi fondasi banyak sistem generator gambar modern.

5. Lanskap AI Generatif Multimodal Saat Ini

- Gambar: Midjourney, DALL-E (OpenAI), Stable Diffusion, Imagen (Google), serta fitur pembuatan gambar terintegrasi di ChatGPT (GPT-4o) dan Gemini.
- Audio/Musik: Suno, Udio, untuk musik; ElevenLabs untuk suara/voice cloning yang sangat realistis.
- Video: Sora (OpenAI), Veo (Google), Runway, Kling, dan lainnya — kategori yang berkembang sangat cepat.
- Model 'serba bisa' (natively multimodal): beberapa model terbaru seperti Gemini dan GPT-4o dirancang untuk memahami DAN menghasilkan berbagai modalitas dalam satu model terpadu, bukan menyambungkan beberapa model terpisah.

Diagram & Ilustrasi

Diffusion Model: Dari Noise Acak Menjadi Gambar



↓ setiap langkah: model 'membersihkan' sedikit noise, dipandu embedding dari deskripsi teks (Tahap 13)

Rangkuman Tahap 16

- AI generatif multimodal menghasilkan konten di luar teks — gambar, audio, dan video — berdasarkan deskripsi (biasanya teks).
- Mayoritas AI generator gambar memakai diffusion model: membersihkan noise acak secara bertahap menjadi gambar koheren, dipandu embedding dari deskripsi teks.
- AI generator video memperluas prinsip ini dengan tantangan tambahan menjaga konsistensi antar-frame dari waktu ke waktu.
- Model seperti CLIP menjembatani teks dan gambar dalam satu ruang embedding yang sama, menjadi fondasi banyak sistem generatif.
- Lanskap saat ini sangat beragam: Midjourney, DALL-E, Stable Diffusion (gambar), Suno/ElevenLabs (audio), Sora/Veo/Runway (video), serta model multimodal terpadu seperti Gemini dan GPT-4o.
- Tahap terakhir Jilid 2 (Tahap 17) akan membahas keterbatasan LLM — hallucination, bias, dan cara mengevaluasi keandalan jawaban AI.

Istilah Penting

Multimodal	Kemampuan AI memproses dan/atau menghasilkan lebih dari satu jenis data: teks, gambar, audio, video.
Diffusion Model	Pendekatan AI generatif yang bekerja dengan membersihkan noise acak secara bertahap menjadi output yang koheren, dipandu oleh deskripsi/kondisi tertentu.
CLIP	Model yang menempatkan teks dan gambar dalam ruang embedding yang sama, menjembatani pemahaman lintas-modalitas.
Text-to-Image / Text-to-Video	Kategori AI generatif yang mengubah deskripsi teks menjadi gambar atau video baru.

SERI BELAJAR AI · JILID 2 · TAHAP 17

Evaluasi, Hallucination & Keterbatasan LLM

Memahami Kapan dan Mengapa AI Bisa Salah

Jilid 2 ini ditutup dengan topik yang sangat penting bagi siapa pun yang memakai AI sehari-hari: memahami keterbatasan LLM. Setelah mempelajari arsitektur Transformer (Tahap 11), cara LLM dilatih (Tahap 12), embedding dan RAG (Tahap 13-14), serta fine-tuning dan AI generatif multimodal (Tahap 15-16), Tahap 17 ini menutup Jilid 2 dengan topik yang sangat praktis: kapan kita boleh percaya jawaban AI, kapan harus curiga, dan bagaimana cara mengevaluasi keandalannya.

1. Apa Itu Hallucination?

Hallucination (dalam konteks AI) adalah ketika model menghasilkan informasi yang terdengar meyakinkan dan ditulis dengan percaya diri, tapi sebenarnya SALAH atau sepenuhnya dikarang. Ini bukan 'kebohongan' yang disengaja (AI tidak punya niat), melainkan konsekuensi alami dari cara kerja LLM: ingat dari Tahap 12, tugas dasar LLM hanyalah menebak kata berikutnya yang PALING MUNGKIN secara statistik — bukan memverifikasi fakta ke sumber aslinya.

Contoh umum: meminta AI menyebutkan referensi/sumber akademik tentang topik yang sangat spesifik, dan AI 'mengarang' judul paper, nama penulis, bahkan nomor halaman yang terdengar sangat meyakinkan tapi tidak benar-benar ada.

■ Analogi

Bayangkan seorang murid yang sangat pandai bicara dan punya memori luas, tapi diminta menjawab ujian lisan tanpa boleh membuka buku. Untuk pertanyaan yang ia benar-benar tahu jawabannya, ia akan menjawab akurat. Tapi untuk pertanyaan yang ia TIDAK yakin jawabannya, alih-alih bilang 'saya tidak tahu', ia cenderung menjawab dengan nada percaya diri berdasarkan 'perkiraan terbaik' — kadang benar, kadang terdengar masuk akal tapi sebenarnya salah. LLM punya kecenderungan serupa, karena dilatih untuk selalu menghasilkan jawaban yang 'terdengar lancar', bukan untuk mengakui ketidaktahuan.

2. Mengapa Hallucination Terjadi?

- LLM menghasilkan jawaban berdasarkan pola statistik dari data latih, bukan dengan 'mencari fakta' secara real-time (kecuali dibantu RAG, lihat Tahap 14, atau fitur pencarian web yang terintegrasi).
- Untuk topik yang jarang muncul dalam data latih, atau topik yang sangat spesifik/niche, model punya lebih sedikit 'bukti pola' untuk menebak dengan akurat, sehingga risiko mengarang jawaban meningkat.
- Model dilatih (lewat RLHF, Tahap 12) untuk menghasilkan jawaban yang TERDENGAR membantu dan percaya diri — ini bisa menjadi pedang bermata dua karena mendorong model tetap menjawab dengan yakin walau sebenarnya tidak yakin.

3. Cara Mengurangi Risiko Hallucination

- Gunakan RAG atau fitur pencarian web (jika tersedia) untuk pertanyaan yang butuh fakta terbaru/spesifik, bukan hanya mengandalkan 'ingatan' model.
- Minta AI menyebutkan sumber, lalu verifikasi sumber itu secara independen — jangan percaya begitu saja walau terdengar meyakinkan.
- Untuk topik berisiko tinggi (medis, hukum, keuangan), selalu silang-cek dengan sumber terpercaya atau ahli manusia; jangan jadikan jawaban AI sebagai satu-satunya rujukan.
- Perhatikan bahwa SEMUA LLM populer saat ini — ChatGPT, Claude, Gemini, Grok, LLaMA — sama-sama berisiko mengalami hallucination, walau tingkat dan karakteristiknya bisa berbeda tergantung data latih dan teknik alignment masing-masing.

4. Bias dalam AI

Selain hallucination, LLM juga bisa mewarisi BIAS dari data pelatihannya. Jika data latih (yang sebagian besar berasal dari internet) mengandung pola bias tertentu — stereotip gender, bias budaya, representasi tidak seimbang antar kelompok — model berisiko mereplikasi atau bahkan memperkuat bias tersebut dalam jawabannya, kecuali ditangani secara khusus lewat proses alignment (Tahap 12).


Perusahaan-perusahaan AI besar (OpenAI, Anthropic, Google, xAI, Meta) masing-masing punya tim dan pendekatan khusus untuk mengurangi bias ini, meski tidak ada yang mengklaim modelnya 100% bebas bias.

5. Cara Mengevaluasi Kualitas Jawaban LLM

- Benchmark otomatis: menguji model dengan ribuan soal standar (matematika, coding, pemahaman bacaan, penalaran) dan membandingkan skor akurasi — dipakai untuk membandingkan GPT, Claude, Gemini, Grok, dan model lain secara objektif pada tugas tertentu.
- Evaluasi manusia (human evaluation): manusia menilai langsung kualitas, keamanan, dan kegunaan jawaban model untuk kasus nyata yang sulit diukur otomatis.
- LLM-as-judge: memakai LLM lain (atau versi model yang lebih besar) untuk menilai kualitas jawaban model lain secara otomatis dalam skala besar — teknik yang makin populer meski punya keterbatasannya sendiri.
- Untuk pengguna sehari-hari, cara paling praktis adalah: selalu berpikir kritis, cross-check untuk hal penting, dan perlakukan AI sebagai 'asisten yang sangat membantu tapi bisa salah' — bukan sumber kebenaran mutlak.

Diagram & Ilustrasi

Kapan Hallucination Berisiko Muncul



Tiga Cara Mengevaluasi Kualitas LLM



Untuk pengguna sehari-hari: bersikap kritis & cross-check untuk hal penting.

Rangkuman Tahap 17

- Hallucination adalah ketika AI menghasilkan jawaban yang terdengar meyakinkan tapi sebenarnya salah/dikarang — konsekuensi alami dari cara kerja LLM yang menebak pola statistik, bukan mencari fakta.
- Risiko hallucination bisa dikurangi lewat RAG, verifikasi sumber, dan sikap kritis pengguna — berlaku untuk semua LLM besar (ChatGPT, Claude, Gemini, Grok, LLaMA).
- LLM juga bisa mewarisi bias dari data pelatihannya, yang coba ditangani lewat proses alignment meski tidak sepenuhnya hilang.
- Evaluasi kualitas LLM memakai kombinasi benchmark otomatis, evaluasi manusia, dan teknik LLM-as-judge.
- Ini menutup Jilid 2: AI Generatif & LLM Lanjutan — dari arsitektur Transformer (Tahap 11) sampai memahami keterbatasan dan cara mengevaluasi AI secara kritis (Tahap 17).

Istilah Penting

Hallucination	Ketika AI menghasilkan informasi yang terdengar meyakinkan namun sebenarnya salah atau dikarang.
Bias	Kecenderungan tidak seimbang/stereotip yang diwarisi model dari pola dalam data pelatihannya.
Benchmark	Kumpulan soal/tugas standar untuk mengukur dan membandingkan kemampuan model AI secara objektif.
Human Evaluation	Penilaian kualitas jawaban AI secara langsung oleh manusia, untuk aspek yang sulit diukur otomatis.
LLM-as-Judge	Teknik menggunakan satu model AI untuk menilai kualitas jawaban model AI lain secara otomatis dalam skala besar.

SERI BELAJAR AI · JILID 2

Penutup & Langkah Selanjutnya

Jilid 2 ini membawa pemahaman kita dari fondasi arsitektur Transformer sampai ke batas kemampuan AI generatif masa kini. Tujuh tahap yang telah dibahas saling berkaitan: attention menjelaskan bagaimana model membaca teks, training menjelaskan bagaimana ia belajar, embedding dan RAG menjelaskan bagaimana ia mengakses pengetahuan, fine-tuning menjelaskan bagaimana ia disesuaikan untuk kebutuhan khusus, AI multimodal menjelaskan bagaimana kemampuannya meluas ke gambar/audio/video, dan evaluasi mengajarkan kita untuk tetap kritis terhadap hasilnya — baik yang dihasilkan ChatGPT, Claude, Gemini, Grok, LLaMA, maupun model lain yang akan terus bermunculan.

Pemahaman ini adalah bekal, bukan titik akhir. Dunia AI generatif bergerak sangat cepat; prinsip-prinsip dasar di buku ini akan tetap relevan untuk memahami model-model baru yang akan muncul di masa depan.

TENTANG BUKU INI

Jilid 2 melanjutkan seri Belajar AI dengan membuka 'kap mesin' model bahasa modern — dari arsitektur Transformer sampai keterbatasan AI generatif terkini.

ISI

- 01 Tahap 11 — Arsitektur Transformer & Attention Mechanism
- 02 Tahap 12 — Next-Token Prediction & Proses Training LLM
- 03 Tahap 13 — Embedding & Semantic Search
- 04 Tahap 14 — RAG (Retrieval-Augmented Generation)
- 05 Tahap 15 — Fine-Tuning vs Prompting
- 06 Tahap 16 — AI Generatif Multimodal (gambar, audio, video)
- 07 Tahap 17 — Evaluasi, Hallucination & Keterbatasan LLM

“Memahami cara kerja AI bukan soal menghafal istilah — tapi membangun intuisi yang bertahan walau teknologinya terus berubah.”