PETA UTAMA

Panduan Memilih Metode Deep Learning

Deep learning adalah machine learning dengan jaringan saraf berlapis banyak. Ia kuat untuk gambar, tulisan, dan suara. Panduan ini membantu Anda memilih model yang cocok hanya dengan menjawab ya atau tidak.

1. Jawab pertanyaan besar di bawah, lalu ikuti kolom **Ya** atau **Tidak**.
2. Baca pertanyaan dari atas. Berhenti di pertanyaan pertama yang jawabannya **Ya**, lalu buka halaman jalurnya.
3. Di halaman jalur, jawab ya atau tidak sampai tiba di **kartu hasil**. Kartu itu berisi metode dan data yang disarankan.

Apakah data Anda sudah punya kunci jawaban?

Artinya setiap data sudah diberi jawaban yang benar. Contoh: foto daun sudah diberi nama penyakitnya, ulasan sudah ditandai positif atau negatif. Istilah resminya: label.

YA — Data sudah punya kunci jawaban

1 Apakah hanya sedikit data yang punya kunci jawaban?
Misalnya 500 dari 50.000 data.
→ **Jalur A · Kunci jawaban hanya sedikit** halaman 2

Tidak ↓

2 Apakah masukannya campuran beberapa jenis data?
Misalnya gambar beserta keterangan tulisannya.
→ **Jalur B · Campuran beberapa jenis data** halaman 2

Tidak ↓

3 Apakah datanya gambar atau video?
Foto, hasil rontgen, citra satelit, rekaman CCTV.
→ **Jalur C · Gambar dan video** halaman 2

Tidak ↓

4 Apakah datanya tulisan?
Ulasan, berita, dokumen, percakapan.
→ **Jalur E · Tulisan** halaman 4

Tidak ↓

5 Apakah datanya suara atau sinyal?
Rekaman suara, detak jantung, getaran mesin.
→ **Jalur F · Suara dan sinyal** halaman 5

Tidak ↓

6 Apakah datanya jaringan hubungan?
Pertemanan, artikel yang saling mengutip, transaksi antar-rekening.
→ **Jalur G · Jaringan hubungan** halaman 5

Tidak ↓

7 Apakah datanya berurutan menurut waktu?
Data harian, bulanan, atau bacaan sensor.
→ **Jalur H · Data berurutan menurut waktu** halaman 5

Tidak ↓

✓ Kalau semua jawabannya Tidak
Data Anda berbentuk tabel (baris dan kolom).
→ **Jalur I · Tabel** halaman 6

TIDAK — Data belum punya kunci jawaban

1 Apakah komputer belajar dengan mencoba, lalu diberi hadiah atau hukuman?
Robot, permainan, pengaturan lampu lalu lintas.
→ **Jalur J · Belajar dari coba-coba** halaman 6

Tidak ↓

2 Apakah Anda ingin komputer membuat data baru?
Tulisan, gambar, atau data tiruan.
→ **Jalur K · Membuat data baru** halaman 7

Tidak ↓

3 Apakah Anda ingin menemukan data yang janggal?
Penipuan, serangan jaringan, kerusakan mesin.
→ **Jalur M · Menemukan data yang janggal** halaman 8

Tidak ↓

4 Apakah Anda ingin mengelompokkan data yang mirip?
Misalnya mengelompokkan gambar atau dokumen.
→ **Jalur N · Mengelompokkan data yang mirip** halaman 8

Tidak ↓

✓ Kalau semua jawabannya Tidak
Anda ingin meringkas data atau menyiapkan model untuk tugas lain.
→ **Jalur O · Meringkas data dan lainnya** halaman 8

Jalur A, Jalur B, Jalur C

Jalur A — Kunci jawaban hanya sedikit

Sebagian besar data belum diberi jawaban.

Belajar dari sedikit jawaban

Istilah resmi: Semi-supervised deep learning

Model belajar dari sedikit data berjawaban, lalu memanfaatkan banyak data tanpa jawaban untuk memperkuat dirinya.

Mulai dari	Model supervised yang dilatih hanya dengan data berlabel
Lalu coba	Pseudo-labeling, Mean Teacher, FixMatch, MixMatch
Data latihan	CIFAR-10 (250 atau 4.000 label), SVHN, STL-10; data sendiri dengan sebagian label disembunyikan
Ukur dengan	Accuracy atau F1 pada test set berlabel; kurva performa terhadap jumlah label

Jalur B — Campuran beberapa jenis data

Model membaca lebih dari satu jenis data sekaligus.

Menggabungkan beberapa jenis data

Istilah resmi: Deep learning multimodal

Model membaca dua jenis data sekaligus, misalnya gambar dan keterangannya, lalu mengambil keputusan dari keduanya.

Mulai dari	Model terpisah per modalitas, lalu late fusion (rata-rata atau concat + MLP)
Lalu coba	CLIP, BLIP, ViLT; fusi dengan cross-attention
Data latihan	MS-COCO Captions, Flickr30k, VQA v2, CMU-MOSEI (sentimen multimodal), Hateful Memes
Ukur dengan	Accuracy/F1 (klasifikasi), Recall@k (retrieval), BLEU/CIDEr (captioning)

Jalur C — Gambar dan video

Tentukan dulu apa yang ingin diketahui dari gambar.

Apakah datanya video?
Gambar bergerak, misalnya rekaman CCTV.

YA

Mengenali isi video

Istilah resmi: Klasifikasi video / pengenalan aksi

Menentukan apa yang terjadi dalam video, misalnya orang berjalan, jatuh, atau menyontek.

Mulai dari	CNN per frame + rata-rata, atau CNN + LSTM
Lalu coba	I3D, R(2+1)D, SlowFast, TSN/TSM
Data latihan	UCF101, HMDB51, Kinetics-400, Something-Something V2, NTU RGB+D
Ukur dengan	Top-1 dan top-5 accuracy, F1 per kelas

TIDAK

Apakah Anda perlu tahu di mana letak bendanya?
Bukan hanya 'ada motor', tetapi 'motornya di sebelah sini'.

YA

Apakah perlu sampai tepi benda yang persis?
Misalnya untuk menghitung luas tumor atau luas lahan.

YA

Mewarnai benda sampai tepinya

Istilah resmi: Segmentasi citra

Menandai setiap titik gambar milik benda apa, misalnya untuk mengukur luas tumor atau lahan sawah.

Mulai dari	U-Net
Lalu coba	DeepLabv3+, U-Net++, Mask R-CNN (instance), nnU-Net (medis)
Data latihan	Cityscapes, ADE20K, Pascal VOC, MS COCO, BraTS, ISIC, DeepGlobe
Ukur dengan	mIoU, Dice coefficient, Hausdorff distance (medis)

TIDAK

Menemukan dan mengotaki benda

Istilah resmi: Deteksi objek

Menunjukkan letak setiap benda dengan kotak, misalnya semua motor di jalan.

Mulai dari	Faster R-CNN atau SSD pra-latih
Lalu coba	YOLO (v5/v8/v11), RetinaNet, Faster R-CNN + FPN
Data latihan	MS COCO, Pascal VOC, Open Images, KITTI, BDD100K, VisDrone
Ukur dengan	mAP@0.5, mAP@[0.5:0.95], precision, recall, FPS

TIDAK

Lanjut ke Jalur D · Memberi nama pada gambar (halaman 3)

Jalur D

Jalur D

Memberi nama pada gambar

Tugasnya sama, tetapi modelnya dipilih sesuai keadaan Anda.

Apakah gambar Anda sedikit?
Di bawah sekitar 1.000 gambar per kategori.

YA

Meminjam model yang sudah pintar

Istilah resmi: Klasifikasi citra dengan transfer learning (data sedikit)

Memakai model yang sudah dilatih dengan jutaan gambar, lalu menyesuaikannya dengan sedikit gambar Anda.

Mulai dari	CNN pra-latih dibekukan sebagai pengekstrak fitur + Logistic Regression/SVM
Lalu coba	Fine-tuning ResNet-50, EfficientNet-B0, DenseNet-121 pra-latih ImageNet
Data latihan	PlantVillage, ISIC, Flowers-102, Oxford-IIIT Pet, data citra sendiri
Ukur dengan	Accuracy, macro-F1, confusion matrix, ROC-AUC

TIDAK

Apakah model harus jalan di ponsel atau alat kecil?
Atau harus menjawab sangat cepat.

YA

Model ringan untuk ponsel dan alat kecil

Istilah resmi: Klasifikasi citra untuk perangkat terbatas

Model kecil dan cepat yang tetap cukup tepat.

Mulai dari	MobileNetV2
Lalu coba	MobileNetV3, EfficientNet-Lite, ShuffleNetV2, SqueezeNet
Data latihan	CIFAR-10/100, ImageNet (subset), Visual Wake Words, data sendiri
Ukur dengan	Accuracy bersama ukuran model (MB), latensi (ms), FPS, memori, energi

TIDAK

Apakah Anda punya data sangat banyak dan komputer yang kuat?
Jutaan gambar dan GPU besar.

YA

Model besar dan terbaru

Istilah resmi: Klasifikasi citra dengan Transformer / CNN modern

Model berukuran besar yang unggul bila data dan komputernya memadai.

Mulai dari	ResNet-50
Lalu coba	Vision Transformer (ViT), Swin Transformer, ConvNeXt, DeiT
Data latihan	ImageNet-1k/21k, iNaturalist, Places365, dataset domain berukuran besar
Ukur dengan	Top-1 dan top-5 accuracy, macro-F1, robustness (ImageNet-C)

TIDAK

Model gambar standar

Istilah resmi: Klasifikasi citra dengan CNN

Pilihan umum yang andal untuk memberi nama pada gambar.

Mulai dari	CNN sederhana (3-5 lapisan konvolusi)
Lalu coba	ResNet, EfficientNet, DenseNet, Inception/Xception
Data latihan	MNIST, Fashion-MNIST, CIFAR-10/100, ImageNet, ChestX-ray14
Ukur dengan	Accuracy, precision, recall, F1 per kelas, confusion matrix, ROC-AUC

Jalur E

Jalur E **Tulisan**
Tentukan dulu bentuk hasil yang Anda inginkan.

Apakah hasilnya berupa tulisan baru?
Terjemahan, ringkasan, atau jawaban.

YA

Apakah jawabannya harus bersumber dari dokumen Anda sendiri?
Misalnya chatbot yang menjawab dari peraturan kampus.

YA

Menjawab berdasarkan dokumen Anda

Istilah resmi: Retrieval-Augmented Generation (RAG)

Komputer mencari bagian dokumen yang cocok, lalu menyusun jawaban dari sana, sehingga tidak mengarang.

Mulai dari	BM25 + LLM tanpa fine-tuning
Lalu coba	Dense retriever (bge, e5, multilingual-e5) + vector database + LLM
Data latihan	Korpus dokumen sendiri; benchmark: Natural Questions, HotpotQA, MS MARCO, TyDi QA (ada bahasa Indonesia)
Ukur dengan	Retrieval: Recall@k, MRR, nDCG. Jawaban: faithfulness, answer relevancy (RAGAS), Exact Match/F1, penilaian manusia

TIDAK

Mengubah tulisan menjadi tulisan lain

Istilah resmi: Teks ke teks (terjemahan, ringkasan)

Menerjemahkan atau meringkas tulisan.

Mulai dari	Lead-3 atau TextRank (ringkasan); LSTM seq2seq + attention
Lalu coba	T5, BART, mT5, mBART, IndoBART, IndoT5
Data latihan	WMT, OPUS, CNN/DailyMail, XSum, IndoSum, Liputan6
Ukur dengan	BLEU, chrF, ROUGE, METEOR, BERTScore, penilaian manusia

TIDAK

Apakah setiap kata perlu diberi tanda?
Misalnya menandai nama orang dan nama tempat.

YA

Menandai kata-kata penting

Istilah resmi: Pelabelan token (NER, POS tagging)

Menandai kata mana yang merupakan nama orang, tempat, atau lembaga di dalam kalimat.

Mulai dari	BiLSTM-CRF
Lalu coba	BERT, IndoBERT, XLM-RoBERTa untuk token classification
Data latihan	CoNLL-2003, OntoNotes 5.0, WikiANN, NERGrit dan POSP (IndoNLU)
Ukur dengan	Precision, recall, F1 tingkat entitas (seqeval)

TIDAK

Apakah contoh berjawaban Anda sangat sedikit?
Hanya puluhan contoh per kategori.

YA

Memilah tulisan dengan sedikit contoh

Istilah resmi: Klasifikasi teks dengan sedikit label

Cukup beberapa puluh contoh per kategori, dengan bantuan model bahasa yang sudah jadi.

Mulai dari	TF-IDF + Logistic Regression
Lalu coba	SetFit (sentence-transformers + contrastive), embedding beku + classifier
Data latihan	Data sendiri; simulasi few-shot pada SST-2, AG News, IndoNLU
Ukur dengan	Accuracy dan macro-F1, dilaporkan sebagai rata-rata ± simpangan baku antar-sampel

TIDAK

Memilah tulisan ke dalam kategori

Istilah resmi: Klasifikasi teks dengan fine-tuning Transformer

Model bahasa yang sudah jadi dilatih lagi dengan data Anda, misalnya untuk ulasan positif atau negatif.

Mulai dari	TF-IDF + SVM; TextCNN atau BiLSTM
Lalu coba	BERT, RoBERTa, IndoBERT, XLM-RoBERTa, DistilBERT
Data latihan	IMDb, SST-2, AG News, IndoNLU (SmSA, EmoT), IndoLEM
Ukur dengan	Accuracy, precision, recall, macro-F1; rata-rata beberapa seed

Jalur F, Jalur G, Jalur H

Jalur F — Suara dan sinyal

Rekaman suara atau sinyal dari alat ukur.

Apakah Anda ingin mengubah ucapan menjadi tulisan?
Misalnya menuliskan isi rekaman kuliah.

YA

Mengubah ucapan menjadi tulisan

Istilah resmi: Pengenalan ucapan (speech to text)

Menuliskan apa yang diucapkan di dalam rekaman.

Mulai dari	Whisper pra-latih tanpa pelatihan ulang
Lalu coba	wav2vec 2.0 atau HuBERT + CTC; Conformer
Data latihan	LibriSpeech, Mozilla Common Voice (ada bahasa Indonesia), FLEURS, TED-LIUM
Ukur dengan	Word Error Rate (WER), Character Error Rate (CER), real-time factor

TIDAK

Mengenali jenis suara atau sinyal

Istilah resmi: Klasifikasi audio / sinyal

Menentukan sebuah rekaman termasuk jenis apa, misalnya detak jantung normal atau tidak.

Mulai dari	MFCC + SVM; CNN 2D kecil pada spektrogram
Lalu coba	CNN pada log-mel spectrogram, CRNN, 1D-CNN pada sinyal mentah
Data latihan	ESC-50, UrbanSound8K, AudioSet, Speech Commands; PhysioNet MIT-BIH (EKG), CWRU Bearing, UCI HAR
Ukur dengan	Accuracy, macro-F1, sensitivitas dan spesifisitas (medis)

Jalur G — Jaringan hubungan

Data berupa titik-titik yang saling terhubung.

Belajar dari jaringan hubungan

Istilah resmi: Graph neural network

Menebak sifat suatu titik atau hubungan baru di dalam jaringan, misalnya rekening mana yang mencurigakan.

Mulai dari	MLP pada fitur node; node2vec + Logistic Regression
Lalu coba	GCN, GraphSAGE, GAT, GIN
Data latihan	Cora, CiteSeer, PubMed, Open Graph Benchmark, Reddit, MoleculeNet/QM9, Elliptic
Ukur dengan	Node: accuracy, macro-F1. Link: ROC-AUC, Hits@k, MRR. Graf: accuracy atau MAE

Jalur H — Data berurutan menurut waktu

Urutan waktu pada data tidak boleh diacak.

Apakah Anda ingin menebak nilai di masa depan?
Misalnya beban listrik besok.

YA

Apakah Anda meramal jauh ke depan, atau banyak hal sekaligus?
Misalnya 30 hari ke depan untuk puluhan sensor.

YA

Meramal jauh ke depan

Istilah resmi: Peramalan horizon panjang / multivariat

Menebak banyak langkah ke depan atau banyak hal sekaligus.

Mulai dari	Seasonal naive, ARIMA, DLinear
Lalu coba	PatchTST, Temporal Fusion Transformer, N-BEATS, N-HiTS, Informer, Autoformer
Data latihan	ETT (ETTh1, ETTm1), Electricity, Traffic, Weather, M4, M5
Ukur dengan	MAE, MSE/RMSE, sMAPE, MASE; CRPS untuk probabilistik

TIDAK

Meramal beberapa langkah ke depan

Istilah resmi: Peramalan horizon pendek

Menebak nilai berikutnya dari data masa lalu, misalnya besok atau minggu depan.

Mulai dari	Naive, ARIMA/SARIMA, Exponential Smoothing
Lalu coba	LSTM, GRU, TCN, CNN-LSTM
Data latihan	Air Passengers, M4, data harga saham (Yahoo Finance), data BPS, BMKG, beban listrik
Ukur dengan	MAE, RMSE, MAPE/sMAPE, MASE

TIDAK

Mengenali pola pada data berurutan

Istilah resmi: Klasifikasi deret waktu

Menentukan sepotong data sensor termasuk kegiatan apa, misalnya berjalan atau berlari.

Mulai dari	1-NN DTW; MiniRocket
Lalu coba	1D-CNN, FCN, ResNet 1D, LSTM/GRU, InceptionTime
Data latihan	UCR/UEA Archive, UCI HAR, WISDM, PhysioNet
Ukur dengan	Accuracy, macro-F1, confusion matrix

Jalur I, Jalur J

Jalur I — Tabel

Untuk data tabel, deep learning tidak selalu pilihan terbaik.

Apakah tabel Anda besar?
Lebih dari sekitar 10.000 baris.

YA — Deep learning untuk tabel besar

Istilah resmi: Deep learning untuk data tabular

Boleh dicoba, tetapi selalu bandingkan dengan gradient boosting yang sering kali menang.

Mulai dari	XGBoost/LightGBM/CatBoost (pembanding wajib); MLP
Lalu coba	MLP dengan embedding kategori, TabNet, FT-Transformer, ResNet tabular
Data latihan	Covertype, Higgs, Adult, California Housing, benchmark OpenML (CC18, TabZilla)
Ukur dengan	Klasifikasi: accuracy, F1, ROC-AUC. Regresi: MAE, RMSE, R^2

TIDAK — Tabel kecil: jangan pakai deep learning

Istilah resmi: Data tabular kecil: deep learning bukan pilihan utama

Untuk tabel kecil, metode klasik biasanya lebih tepat, lebih cepat, dan lebih mudah dijelaskan.

Mulai dari	Logistic/Linear Regression
Lalu coba	Random Forest, XGBoost, LightGBM, CatBoost
Data latihan	UCI Adult, Breast Cancer Wisconsin, Pima Diabetes, data sendiri
Ukur dengan	Klasifikasi: F1, ROC-AUC, MCC. Regresi: MAE, RMSE

Jalur J — Belajar dari coba-coba

Komputer mencoba suatu tindakan, lalu belajar dari hadiah atau hukuman.

Apakah yang diatur berupa nilai yang bisa naik-turun secara halus?
Halus: sudut kemudi, kecepatan. Tidak halus: kiri, kanan, maju.

YA — Belajar mengendalikan gerakan halus

Istilah resmi: Deep RL dengan aksi kontinu

Belajar mengatur nilai yang bisa naik-turun sedikit demi sedikit, misalnya gerak lengan robot.

Mulai dari	Kebijakan acak, pengendali PID, REINFORCE
Lalu coba	PPO, SAC, TD3, DDPG
Data latihan	Lingkungan: MuJoCo (Gymnasium), DeepMind Control Suite, PyBullet, Isaac Lab
Ukur dengan	Average return, sample efficiency, tingkat keberhasilan, interquartile mean

TIDAK — Belajar memilih langkah

Istilah resmi: Deep RL dengan aksi diskret

Belajar memilih satu dari beberapa langkah, misalnya dalam permainan atau lampu lalu lintas.

Mulai dari	DQN
Lalu coba	Double DQN, Dueling DQN, Rainbow, A2C, PPO
Data latihan	Lingkungan: CartPole, LunarLander, Atari (ALE), MiniGrid, PettingZoo, SUMO
Ukur dengan	Average return, human-normalized score, sample efficiency

Jalur K, Jalur L

Jalur K — Membuat data baru

Komputer menghasilkan sesuatu yang belum ada.

Apakah yang dibuat berupa tulisan?
Jawaban chatbot, draf dokumen.

YA

Membuat tulisan baru

Istilah resmi: Generasi teks dengan LLM

Komputer menulis jawaban, ringkasan, atau draf, misalnya chatbot.

Mulai dari	GPT-2 fine-tuning; LLM dengan prompt tanpa pelatihan
Lalu coba	LLM terbuka (Llama, Mistral, Qwen, Gemma) dengan LoRA/QLoRA
Data latihan	WikiText-103, OpenWebText, dataset instruksi (Alpaca, Dolly), korpus domain sendiri
Ukur dengan	Perplexity, BLEU/ROUGE, BERTScore, penilaian manusia, penilaian LLM-as-judge dengan rubrik

TIDAK

Apakah yang dibuat berupa gambar?
Gambar medis tambahan, ilustrasi.

YA

Lanjut ke Jalur L · Membuat gambar (halaman 7)

TIDAK

Membuat data tiruan

Istilah resmi: Data sintetis tabular / deret waktu

Membuat tabel atau data berurutan buatan yang mirip aslinya, agar data asli yang rahasia tidak perlu dibagikan.

Mulai dari	SMOTE atau Gaussian Copula
Lalu coba	CTGAN, TVAE; TimeGAN (deret waktu)
Data latihan	Adult, Covertype, Credit Default; data sendiri yang sensitif
Ukur dengan	Fidelity (uji KS, selisih korelasi), utility (train on synthetic, test on real), privasi (distance to closest record)

Jalur L — Membuat gambar

Ada tiga keluarga model pembuat gambar.

Apakah gambar ingin diarahkan dengan kalimat, atau mutu tertinggi yang diutamakan?
Misalnya 'buat foto daun padi berbercak cokelat'.

YA

Membuat gambar dari kalimat

Istilah resmi: Generasi citra dengan diffusion

Membuat gambar bermutu tinggi yang bisa diarahkan dengan kalimat.

Mulai dari	VAE atau DCGAN
Lalu coba	DDPM, DDIM, Latent Diffusion / Stable Diffusion
Data latihan	CIFAR-10, CelebA-HQ, FFHQ, LSUN, ImageNet, LAION (teks ke citra)
Ukur dengan	FID, KID, Inception Score, CLIP score, precision/recall generatif

TIDAK

Apakah Anda ingin mengubah gambar dari satu bentuk ke bentuk lain?
Sketsa menjadi foto, foto siang menjadi malam.

YA

Mengubah bentuk gambar

Istilah resmi: Translasi citra ke citra

Mengubah gambar dari satu bentuk ke bentuk lain, misalnya sketsa menjadi foto.

Mulai dari	U-Net dengan loss L1
Lalu coba	Pix2Pix (data berpasangan), CycleGAN (tidak berpasangan)
Data latihan	Cityscapes, Facades, Maps, horse2zebra; pasangan citra medis (MRI ke CT)
Ukur dengan	FID, SSIM, PSNR, LPIPS; penilaian manusia atau ahli

TIDAK

Membuat gambar baru yang mirip contoh

Istilah resmi: Generasi citra dengan GAN / VAE

Dua model saling beradu: satu membuat gambar, satu lagi menilai asli atau palsu.

Mulai dari	VAE
Lalu coba	DCGAN, WGAN-GP, conditional GAN
Data latihan	MNIST, CIFAR-10, CelebA, FFHQ, LSUN
Ukur dengan	FID, KID, Inception Score, precision/recall generatif

Jalur M, Jalur N, Jalur O

Jalur M — Menemukan data yang janggal

Model belajar seperti apa data yang normal, lalu menandai yang berbeda.

Apakah datanya berurutan menurut waktu?
Bacaan sensor atau catatan sistem dari waktu ke waktu.

YA

Mencari kejadian janggal dari waktu ke waktu

Istilah resmi: Deteksi anomali deret waktu dengan deep learning

Menemukan saat ketika sensor atau sistem berperilaku tidak seperti biasanya.

Mulai dari	Rolling z-score; Isolation Forest pada fitur jendela
Lalu coba	LSTM Autoencoder, galat prediksi LSTM, USAD
Data latihan	NAB, Yahoo S5, SMD, SMAP/MSL, SWaT/WADI, UCR Anomaly Archive
Ukur dengan	PR-AUC, F1 berbasis rentang, VUS, keterlambatan deteksi; laporkan F1 dengan dan tanpa point adjustment

TIDAK

Mencari data yang janggal

Istilah resmi: Deteksi anomali dengan deep learning

Model belajar membangun ulang data normal; data yang gagal dibangun ulang dianggap janggal.

Mulai dari	Isolation Forest, One-Class SVM (pembanding wajib)
Lalu coba	Autoencoder, Variational Autoencoder, Deep SVDD, DAGMM
Data latihan	NSL-KDD, UNSW-NB15, CIC-IDS2017, N-BaIoT, IoT-23, Credit Card Fraud; citra: MVTec AD
Ukur dengan	ROC-AUC, PR-AUC, F1 pada ambang terpilih, false positive rate

Jalur N — Mengelompokkan data yang mirip

Untuk data rumit seperti gambar atau dokumen.

Mengelompokkan data rumit

Istilah resmi: Deep clustering

Model meringkas data dulu, lalu mengelompokkan ringkasannya.

Mulai dari	K-Means pada fitur asli atau hasil PCA
Lalu coba	Autoencoder + K-Means, Deep Embedded Clustering (DEC), IDEC
Data latihan	MNIST, Fashion-MNIST, CIFAR-10, STL-10, Reuters-10k
Ukur dengan	Clustering accuracy (ACC), NMI, ARI; silhouette bila tanpa label

Jalur O — Meringkas data dan lainnya

Menyederhanakan data atau menyiapkan model.

Apakah Anda ingin meringkas data menjadi bentuk yang lebih pendek?
Misalnya ratusan kolom menjadi belasan angka.

YA

Meringkas data secara otomatis

Istilah resmi: Autoencoder untuk reduksi dimensi / representasi

Model belajar memampatkan data menjadi ringkasan pendek, lalu membangunnya kembali.

Mulai dari	PCA
Lalu coba	Autoencoder, Denoising Autoencoder, Sparse Autoencoder
Data latihan	MNIST, Fashion-MNIST, data ekspresi gen, data trafik jaringan
Ukur dengan	Galat rekonstruksi; performa model hilir pada representasi laten

TIDAK

Apakah Anda punya banyak data tanpa jawaban dan ingin model berlatih sendiri dulu?
Hasil latihannya dipakai untuk tugas lain.

YA

Berlatih sendiri dari data mentah

Istilah resmi: Pra-pelatihan self-supervised

Model membuat soal latihan sendiri dari data tanpa jawaban agar paham polanya, lalu dipakai untuk tugas lain.

Mulai dari	Model supervised dari nol; model pra-latih umum (ImageNet)
Lalu coba	SimCLR, MoCo, BYOL, DINO, MAE (citra); masked language modeling (teks); wav2vec 2.0 (audio); TS2Vec (deret waktu)
Data latihan	ImageNet, CIFAR-10/100, STL-10; korpus domain tak berlabel berukuran besar
Ukur dengan	Linear probing, fine-tuning dengan 1%/10% label, akurasi kNN pada embedding

TIDAK

Mungkin tidak perlu deep learning

Istilah resmi: Deep learning mungkin tidak diperlukan

Tulis dulu dalam satu kalimat: apa masukannya dan apa hasil yang diinginkan. Lalu coba panduan machine learning umum.

Mulai dari	Exploratory data analysis
Lalu coba	Rumuskan ulang masukan, keluaran, dan ukuran keberhasilan; gunakan peta keputusan machine learning umum
Data latihan	Belum dapat ditentukan
Ukur dengan	Belum dapat ditentukan

Sesuaikan dengan keadaan Anda

Periksa daftar ini satu per satu. Kalau jawabannya Ya, tambahkan sarannya ke rancangan penelitian Anda.

Kalau jawabannya Ya...

Data latih Anda sedikit?

Ratusan, bukan puluhan ribu.

- Pinjam model yang sudah dilatih orang lain (transfer learning); jangan melatih dari nol.
- Perbanyak data dengan variasi buatan: gambar diputar, dipotong, dibalik.
- Uji berulang kali (k-fold) agar hasilnya bukan kebetulan.

Satu kategori jauh lebih banyak dari yang lain?

Misalnya 95% normal dan 5% sakit.

- Beri bobot lebih pada kategori yang sedikit (class weight atau focal loss).
- Jangan hanya melihat akurasi; laporkan F1 dan recall tiap kategori.

Nilai latihan tinggi, tetapi nilai ujian rendah?

Model menghafal, bukan memahami (overfitting).

- Tambahkan dropout, weight decay, dan variasi data.
- Hentikan pelatihan lebih awal (early stopping) atau kecilkan model.
- Periksa apakah ada data yang sama di data latih dan data uji.

Pelatihan kacau?

Angka kesalahan (loss) naik-turun tajam atau tidak mau turun.

- Kecilkan learning rate; pakai warmup.
- Pakai gradient clipping dan pastikan data masukan sudah dinormalkan.
- Coba dulu pada sedikit data: model harus mampu menghafalnya.

Keputusan model harus bisa dijelaskan?

Keputusan medis atau akademik.

- Untuk gambar: Grad-CAM menunjukkan bagian gambar yang diperhatikan model.
- Untuk tulisan dan tabel: SHAP atau Integrated Gradients.

Model harus jalan di ponsel atau alat kecil?

Atau harus menjawab sangat cepat.

- Pilih model ringan seperti MobileNet atau DistilBERT.
- Kecilkan dengan quantization, pruning, atau distillation.
- Ukur kecepatan pada alat yang sebenarnya, bukan di komputer besar.

Data tersebar dan tidak boleh dikumpulkan?

Data antar-rumah sakit atau perangkat IoT.

- Pakai federated learning: yang berkeliling adalah modelnya, bukan datanya.
- Mulai dari FedAvg; pustaka yang mudah: Flower.

Perlu tahu seberapa yakin model?

Agar model boleh berkata 'saya ragu'.

- Pakai MC Dropout atau gabungan beberapa model (ensemble).
- Rapikan angka keyakinan dengan temperature scaling.

Komputer Anda tanpa GPU?

Hanya laptop biasa.

- Pakai Google Colab atau Kaggle yang gratis.
- Pakai model yang sudah jadi sebagai pengolah awal, lalu latih bagian kecil saja.
- Untuk model bahasa besar, pakai LoRA agar hemat.

Kebiasaan baik untuk semua penelitian

1. Tulis tujuan dalam satu kalimat: apa masukannya, apa hasilnya, dan diukur dengan apa.
2. Sisihkan data uji sejak awal dan jangan disentuh sampai percobaan terakhir.
3. Selalu bandingkan dengan metode sederhana (baris 'Mulai dari' pada kartu). Deep learning tidak otomatis lebih baik.
4. Mulai dari model yang sudah dilatih orang lain; melatih dari nol jarang diperlukan.
5. Ulangi pelatihan dengan beberapa angka acak awal (seed) dan laporkan rata-ratanya.
6. Pantau grafik kesalahan data latih dan data validasi selama pelatihan.
7. Catat semua pengaturan dan versi pustaka supaya orang lain bisa mengulang.
8. Cari data dan model siap pakai di Hugging Face, Kaggle, dan Papers with Code.

Kamus istilah

Istilah yang muncul di kartu hasil, dijelaskan dengan bahasa sehari-hari.

Jaringan saraf
Susunan banyak rumus kecil (neuron) yang saling terhubung dan belajar bersama.

Lapisan (layer)
Satu tingkat neuron. 'Deep' berarti lapisannya banyak.

Arsitektur
Rancangan susunan lapisan. Contoh: CNN, Transformer.

Bobot (weight)
Angka-angka di dalam model yang diubah selama belajar. Inilah 'ingatan' model.

Loss
Angka yang menunjukkan seberapa salah tebakan model. Tujuan pelatihan adalah mengecilkannya.

Optimizer
Cara memperbaiki bobot agar loss turun. Contoh: Adam, SGD.

Learning rate
Besar langkah setiap kali bobot diperbaiki. Terlalu besar kacau, terlalu kecil lambat.

Epoch
Satu kali model melihat seluruh data latih.

Batch
Sekelompok kecil data yang diproses bersamaan dalam satu langkah.

Overfitting
Model menghafal data latih tetapi gagal pada data baru.

Dropout
Mematikan sebagian neuron secara acak saat latihan agar model tidak menghafal.

Augmentasi
Membuat variasi data, misalnya gambar diputar atau dibalik, agar data terasa lebih banyak.

Model pra-latih (pretrained)
Model yang sudah dilatih orang lain dengan data sangat besar dan siap dipakai.

Fine-tuning
Melatih lagi model pra-latih dengan data sendiri.

Transfer learning
Memakai pengetahuan model pra-latih untuk tugas baru.

CNN
Jaringan ahli gambar; mengenali pola seperti garis, tekstur, dan bentuk.

RNN, LSTM, GRU
Jaringan ahli data berurutan; mengingat apa yang datang sebelumnya.

Transformer
Jaringan yang melihat seluruh masukan sekaligus dan memilih bagian yang penting (attention). Dasar model bahasa modern.

LLM
Model bahasa besar yang bisa menulis dan menjawab, seperti GPT atau Llama.

RAG
LLM yang lebih dulu mencari di dokumen Anda, baru kemudian menjawab.

LoRA
Cara hemat melatih LLM: hanya sebagian kecil bobot yang diubah.

Embedding
Daftar angka yang mewakili makna sebuah kata, gambar, atau dokumen.

Autoencoder
Model yang memampatkan data lalu membangunnya kembali.

GAN
Dua model yang beradu: pembuat data palsu dan penilai asli atau palsu.

Diffusion
Model pembuat gambar yang belajar membersihkan gambar berbintik sedikit demi sedikit.

GPU
Kartu grafis; komponen komputer yang mempercepat pelatihan deep learning.

Quantization
Mengecilkan model dengan menyederhanakan angka-angkanya.

mAP dan IoU
Ukuran ketepatan kotak atau warna pada tugas menemukan benda. Semakin tinggi semakin baik.

FID
Ukuran kemiripan gambar buatan dengan gambar asli. Semakin kecil semakin baik.

WER
Persentase kata yang salah saat mengubah ucapan menjadi tulisan. Semakin kecil semakin baik.

Peta Keluarga Deep Learning

Setiap warna adalah satu keluarga. Kotak berwarna menjelaskan keluarganya dengan bahasa sederhana; semakin jauh dari tengah, semakin spesifik sampai ke nama metode.

