# Peta Keputusan Riset Deep Learning

Jawab setiap pertanyaan dengan ya atau tidak sampai tiba di kotak hasil. Hasil menunjukkan jenis tugas dan arsitektur utamanya; rincian lengkap ada di halaman berikutnya.

Pertanyaan · YA · TIDAK · Jawaban yang membawa ke kotak itu · Hasil (nomor H merujuk ke halaman rincian); baris kecil adalah arsitektur utama · Baca dari kiri ke kanan, mulai dari kotak gelap.

- Apakah data Anda memiliki label atau target yang ingin diprediksi?
  - YA: Apakah hanya sebagian kecil data yang berlabel, sedangkan sebagian besar belum?
    - YA: **H1 · Semi-supervised deep learning** — Pseudo-labeling, Mean Teacher, FixMatch, MixMatch
    - TIDAK: Apakah masukan terdiri atas lebih dari satu jenis data (misalnya citra dan teks)?
      - YA: **H2 · Deep learning multimodal** — CLIP, BLIP, ViLT; fusi dengan cross-attention
      - TIDAK: Apakah data utama berupa citra atau video?
        - YA: Apakah datanya video (ada dimensi waktu antar-frame)?
          - YA: Apakah Anda perlu mengetahui letak objek di dalam citra, bukan hanya satu label untuk seluruh citra?
            - YA: **H3 · Klasifikasi video / pengenalan aksi** — I3D, R(2+1)D, SlowFast, TSN/TSM
            - TIDAK: Apakah batas objek dibutuhkan sampai tingkat piksel?
              - YA: **H4 · Segmentasi citra** — DeepLabv3+, U-Net++, Mask R-CNN (instance), nnU-Net (medis)
              - TIDAK: **H5 · Deteksi objek** — YOLO (v5/v8/v11), RetinaNet, Faster R-CNN + FPN
          - TIDAK: Apakah data berlabel sedikit (di bawah sekitar 1.000 citra per kelas)?
            - YA: **H6 · Klasifikasi citra dengan transfer learning (data sedikit)** — Fine-tuning ResNet-50, EfficientNet-B0, DenseNet-121 pra-latih ImageNet
            - TIDAK: Apakah model harus berjalan real-time atau di perangkat terbatas (ponsel, IoT)?
              - YA: **H7 · Klasifikasi citra untuk perangkat terbatas** — MobileNetV3, EfficientNet-Lite, ShuffleNetV2, SqueezeNet
              - TIDAK: Apakah tersedia data sangat besar atau GPU yang kuat?
                - YA: **H8 · Klasifikasi citra dengan Transformer / CNN modern** — Vision Transformer (ViT), Swin Transformer, ConvNeXt, DeiT
                - TIDAK: **H9 · Klasifikasi citra dengan CNN** — ResNet, EfficientNet, DenseNet, Inception/Xception
        - TIDAK: Apakah data utama berupa teks bahasa alami?
          - YA: Apakah keluarannya berupa teks baru (terjemahan, ringkasan, jawaban)?
            - YA: Apakah jawaban harus bersumber dari dokumen Anda sendiri atau informasi terkini?
              - YA: **H10 · Retrieval-Augmented Generation (RAG)** — Dense retriever (bge, e5, multilingual-e5) + vector database + LLM
              - TIDAK: **H11 · Teks ke teks (terjemahan, ringkasan)** — T5, BART, mT5, mBART, IndoBART, IndoT5
            - TIDAK: Apakah label diberikan untuk setiap kata/token (nama orang, lokasi, kelas kata)?
              - YA: **H12 · Pelabelan token (NER, POS tagging)** — BERT, IndoBERT, XLM-RoBERTa untuk token classification
              - TIDAK: Apakah data berlabel sangat sedikit (puluhan contoh per kelas)?
                - YA: **H13 · Klasifikasi teks dengan sedikit label** — SetFit (sentence-transformers + contrastive), embedding beku + classifier
                - TIDAK: **H14 · Klasifikasi teks dengan fine-tuning Transformer** — BERT, RoBERTa, IndoBERT, XLM-RoBERTa, DistilBERT
          - TIDAK: Apakah data utama berupa audio atau sinyal (suara, EEG, EKG, getaran)?
            - YA: Apakah tujuannya mengubah ucapan menjadi teks?
              - YA: **H15 · Pengenalan ucapan (speech to text)** — wav2vec 2.0 atau HuBERT + CTC; Conformer
              - TIDAK: **H16 · Klasifikasi audio / sinyal** — CNN pada log-mel spectrogram, CRNN, 1D-CNN pada sinyal mentah
            - TIDAK: Apakah data berbentuk graf/jaringan (simpul dan relasi)?
              - YA: **H17 · Graph neural network** — GCN, GraphSAGE, GAT, GIN
              - TIDAK: Apakah urutan waktu pada data penting (deret waktu)?
                - YA: Apakah Anda ingin memprediksi nilai pada waktu mendatang?
                  - YA: Apakah horizon prediksinya panjang atau variabelnya banyak?
                    - YA: **H18 · Peramalan horizon panjang / multivariat** — PatchTST, Temporal Fusion Transformer, N-BEATS, N-HiTS, Informer, Autoformer
                    - TIDAK: **H19 · Peramalan horizon pendek** — LSTM, GRU, TCN, CNN-LSTM
                  - TIDAK: **H20 · Klasifikasi deret waktu** — 1D-CNN, FCN, ResNet 1D, LSTM/GRU, InceptionTime
                - TIDAK: Apakah data tabular Anda besar (lebih dari sekitar 10.000 baris)?
                  - YA: **H21 · Deep learning untuk data tabular** — MLP dengan embedding kategori, TabNet, FT-Transformer, ResNet tabular
                  - TIDAK: **H22 · Data tabular kecil: deep learning bukan pilihan utama** — Random Forest, XGBoost, LightGBM, CatBoost
  - TIDAK: Apakah sistem belajar dari interaksi coba-coba dengan lingkungan dan menerima reward?
    - YA: Apakah aksinya bernilai kontinu (sudut, torsi, kecepatan)?
      - YA: **H23 · Deep RL dengan aksi kontinu** — PPO, SAC, TD3, DDPG
      - TIDAK: **H24 · Deep RL dengan aksi diskret** — Double DQN, Dueling DQN, Rainbow, A2C, PPO
    - TIDAK: Apakah tujuannya menghasilkan data baru (teks, citra, data sintetis)?
      - YA: Apakah yang dihasilkan berupa teks?
        - YA: **H25 · Generasi teks dengan LLM** — LLM terbuka (Llama, Mistral, Qwen, Gemma) dengan LoRA/QLoRA
        - TIDAK: Apakah yang dihasilkan berupa citra?
          - YA: Apakah hasil perlu dikendalikan dengan teks, atau kualitas dan keragaman tertinggi menjadi prioritas?
            - YA: **H26 · Generasi citra dengan diffusion** — DDPM, DDIM, Latent Diffusion / Stable Diffusion
            - TIDAK: Apakah tujuannya mengubah citra dari satu domain ke domain lain?
              - YA: **H27 · Translasi citra ke citra** — Pix2Pix (data berpasangan), CycleGAN (tidak berpasangan)
              - TIDAK: **H28 · Generasi citra dengan GAN / VAE** — DCGAN, WGAN-GP, conditional GAN
          - TIDAK: **H29 · Data sintetis tabular / deret waktu** — CTGAN, TVAE; TimeGAN (deret waktu)
      - TIDAK: Apakah tujuannya menemukan data yang menyimpang dari pola normal (anomali, intrusi, fraud)?
        - YA: Apakah datanya deret waktu atau aliran data sensor/log?
          - YA: **H30 · Deteksi anomali deret waktu dengan deep learning** — LSTM Autoencoder, galat prediksi LSTM, USAD
          - TIDAK: **H31 · Deteksi anomali dengan deep learning** — Autoencoder, Variational Autoencoder, Deep SVDD, DAGMM
        - TIDAK: Apakah tujuannya mengelompokkan data yang mirip ke dalam grup?
          - YA: **H32 · Deep clustering** — Autoencoder + K-Means, Deep Embedded Clustering (DEC), IDEC
          - TIDAK: Apakah tujuannya meringkas data menjadi representasi berdimensi rendah?
            - YA: **H33 · Autoencoder untuk reduksi dimensi / representasi** — Autoencoder, Denoising Autoencoder, Sparse Autoencoder
            - TIDAK: Apakah Anda punya banyak data tak berlabel dan ingin pra-melatih model untuk tugas lain?
              - YA: **H34 · Pra-pelatihan self-supervised** — SimCLR, MoCo, BYOL, DINO, MAE (citra); masked language modeling (teks); wav2vec 2.0 (audio); TS2Vec (deret waktu)
              - TIDAK: **H35 · Deep learning mungkin tidak diperlukan** — Rumuskan ulang masukan, keluaran, dan ukuran keberhasilan; gunakan peta keputusan machine learning umum

# Rincian Hasil Peta Keputusan Deep Learning

Untuk setiap hasil: baseline, arsitektur utama, lanjutan, dataset pembanding, resep pelatihan, metrik, dan jebakan umum.

## Rincian setiap hasil

### H1 · Semi-supervised deep learning

Semi-supervised

| | |
|---|---|
| Baseline | Model supervised yang dilatih hanya dengan data berlabel |
| Arsitektur | Pseudo-labeling, Mean Teacher, FixMatch, MixMatch |
| Lanjutan | FlexMatch, pra-pelatihan self-supervised lalu fine-tuning dengan sedikit label |
| Dataset | CIFAR-10 (250 atau 4.000 label), SVHN, STL-10; data sendiri dengan sebagian label disembunyikan |
| Pelatihan | Cross-entropy pada data berlabel + consistency loss pada data tak berlabel; augmentasi lemah dan kuat; ambang kepercayaan pseudo-label |
| Metrik | Accuracy atau F1 pada test set berlabel; kurva performa terhadap jumlah label |
| Jebakan | Pseudo-label salah memperkuat dirinya sendiri; distribusi data tak berlabel berbeda dari data berlabel |

### H2 · Deep learning multimodal

Supervised / pra-latih multimodal

| | |
|---|---|
| Baseline | Model terpisah per modalitas, lalu late fusion (rata-rata atau concat + MLP) |
| Arsitektur | CLIP, BLIP, ViLT; fusi dengan cross-attention |
| Lanjutan | Vision-language model (LLaVA, Qwen-VL) dengan LoRA |
| Dataset | MS-COCO Captions, Flickr30k, VQA v2, CMU-MOSEI (sentimen multimodal), Hateful Memes |
| Pelatihan | Encoder pra-latih per modalitas dibekukan dulu, lalu dibuka bertahap; contrastive loss (InfoNCE) atau cross-entropy; AdamW |
| Metrik | Accuracy/F1 (klasifikasi), Recall@k (retrieval), BLEU/CIDEr (captioning) |
| Jebakan | Satu modalitas mendominasi; modalitas hilang saat inferensi; tidak ada ablation per modalitas |

### H3 · Klasifikasi video / pengenalan aksi

Supervised

| | |
|---|---|
| Baseline | CNN per frame + rata-rata, atau CNN + LSTM |
| Arsitektur | I3D, R(2+1)D, SlowFast, TSN/TSM |
| Lanjutan | TimeSformer, Video Swin, VideoMAE |
| Dataset | UCF101, HMDB51, Kinetics-400, Something-Something V2, NTU RGB+D |
| Pelatihan | Sampling 8-32 frame per klip; bobot pra-latih Kinetics; cross-entropy; AdamW atau SGD; augmentasi temporal dan spasial |
| Metrik | Top-1 dan top-5 accuracy, F1 per kelas |
| Jebakan | Klip dari video sumber yang sama berada di latih dan uji; kebutuhan GPU diremehkan |

### H4 · Segmentasi citra

Supervised

| | |
|---|---|
| Baseline | U-Net |
| Arsitektur | DeepLabv3+, U-Net++, Mask R-CNN (instance), nnU-Net (medis) |
| Lanjutan | SegFormer, Mask2Former, Segment Anything (SAM) dengan prompt atau fine-tuning |
| Dataset | Cityscapes, ADE20K, Pascal VOC, MS COCO, BraTS, ISIC, DeepGlobe |
| Pelatihan | Loss Dice + cross-entropy (atau focal untuk kelas kecil); encoder pra-latih ImageNet; augmentasi yang sama pada citra dan mask; patching untuk citra besar |
| Metrik | mIoU, Dice coefficient, Hausdorff distance (medis) |
| Jebakan | Pixel accuracy tinggi karena latar belakang dominan; mask tidak selaras setelah augmentasi |

### H5 · Deteksi objek

Supervised

| | |
|---|---|
| Baseline | Faster R-CNN atau SSD pra-latih |
| Arsitektur | YOLO (v5/v8/v11), RetinaNet, Faster R-CNN + FPN |
| Lanjutan | DETR, RT-DETR, Grounding DINO (open-vocabulary) |
| Dataset | MS COCO, Pascal VOC, Open Images, KITTI, BDD100K, VisDrone |
| Pelatihan | Fine-tuning dari bobot COCO; loss box (IoU/GIoU/CIoU) + klasifikasi; augmentasi mosaic, skala, flip; anotasi dengan CVAT/Roboflow |
| Metrik | mAP@0.5, mAP@[0.5:0.95], precision, recall, FPS |
| Jebakan | Frame berurutan dari video yang sama di latih dan uji; anotasi tidak konsisten; objek kecil terabaikan |

### H6 · Klasifikasi citra dengan transfer learning (data sedikit)

Supervised + transfer learning

| | |
|---|---|
| Baseline | CNN pra-latih dibekukan sebagai pengekstrak fitur + Logistic Regression/SVM |
| Arsitektur | Fine-tuning ResNet-50, EfficientNet-B0, DenseNet-121 pra-latih ImageNet |
| Lanjutan | Fitur DINOv2 atau CLIP + linear probe; few-shot (Prototypical Networks) |
| Dataset | PlantVillage, ISIC, Flowers-102, Oxford-IIIT Pet, data citra sendiri |
| Pelatihan | Bekukan backbone lalu latih kepala; buka lapisan atas dengan learning rate kecil (1e-4 sampai 1e-5); augmentasi kuat; early stopping; stratified k-fold |
| Metrik | Accuracy, macro-F1, confusion matrix, ROC-AUC |
| Jebakan | Melatih dari nol pada data kecil (overfitting); citra objek yang sama di latih dan uji; augmentasi diterapkan pada data uji |

### H7 · Klasifikasi citra untuk perangkat terbatas

Supervised

| | |
|---|---|
| Baseline | MobileNetV2 |
| Arsitektur | MobileNetV3, EfficientNet-Lite, ShuffleNetV2, SqueezeNet |
| Lanjutan | Knowledge distillation dari model besar, quantization-aware training, pruning |
| Dataset | CIFAR-10/100, ImageNet (subset), Visual Wake Words, data sendiri |
| Pelatihan | Fine-tuning lalu post-training quantization (INT8); ekspor ke TensorFlow Lite atau ONNX; ukur pada perangkat sasaran |
| Metrik | Accuracy bersama ukuran model (MB), latensi (ms), FPS, memori, energi |
| Jebakan | Hanya melaporkan akurasi; latensi diukur di GPU desktop, bukan di perangkat sasaran; akurasi turun setelah quantization |

### H8 · Klasifikasi citra dengan Transformer / CNN modern

Supervised

| | |
|---|---|
| Baseline | ResNet-50 |
| Arsitektur | Vision Transformer (ViT), Swin Transformer, ConvNeXt, DeiT |
| Lanjutan | Pra-latih self-supervised (MAE, DINOv2) lalu fine-tuning; EVA, model fondasi visi |
| Dataset | ImageNet-1k/21k, iNaturalist, Places365, dataset domain berukuran besar |
| Pelatihan | AdamW, cosine schedule dengan warmup, label smoothing, MixUp/CutMix, RandAugment, mixed precision |
| Metrik | Top-1 dan top-5 accuracy, macro-F1, robustness (ImageNet-C) |
| Jebakan | ViT dari nol pada data kecil kalah dari CNN; biaya komputasi dan jejak karbon tidak dilaporkan |

### H9 · Klasifikasi citra dengan CNN

Supervised

| | |
|---|---|
| Baseline | CNN sederhana (3-5 lapisan konvolusi) |
| Arsitektur | ResNet, EfficientNet, DenseNet, Inception/Xception |
| Lanjutan | ConvNeXt, ensemble beberapa CNN, attention module (SE, CBAM) |
| Dataset | MNIST, Fashion-MNIST, CIFAR-10/100, ImageNet, ChestX-ray14 |
| Pelatihan | Cross-entropy; Adam atau SGD + momentum; batch normalization; dropout; augmentasi (flip, rotasi, crop); early stopping |
| Metrik | Accuracy, precision, recall, F1 per kelas, confusion matrix, ROC-AUC |
| Jebakan | Overfitting; data leakage antar-split; tidak ada pembanding pra-latih |

### H10 · Retrieval-Augmented Generation (RAG)

LLM + retrieval

| | |
|---|---|
| Baseline | BM25 + LLM tanpa fine-tuning |
| Arsitektur | Dense retriever (bge, e5, multilingual-e5) + vector database + LLM |
| Lanjutan | Hybrid search, reranker (cross-encoder), GraphRAG, fine-tuning retriever, agentic RAG |
| Dataset | Korpus dokumen sendiri; benchmark: Natural Questions, HotpotQA, MS MARCO, TyDi QA (ada bahasa Indonesia) |
| Pelatihan | Chunking dokumen (200-800 token, dengan overlap); pilih embedding multibahasa; prompt dengan kutipan sumber; siapkan set pertanyaan-jawaban emas |
| Metrik | Retrieval: Recall@k, MRR, nDCG. Jawaban: faithfulness, answer relevancy (RAGAS), Exact Match/F1, penilaian manusia |
| Jebakan | Halusinasi saat dokumen tidak ditemukan; chunk terlalu besar atau kecil; evaluasi hanya dengan contoh pilihan sendiri |

### H11 · Teks ke teks (terjemahan, ringkasan)

Supervised / LLM

| | |
|---|---|
| Baseline | Lead-3 atau TextRank (ringkasan); LSTM seq2seq + attention |
| Arsitektur | T5, BART, mT5, mBART, IndoBART, IndoT5 |
| Lanjutan | LLM terbuka (Llama, Mistral, Qwen) dengan LoRA/QLoRA |
| Dataset | WMT, OPUS, CNN/DailyMail, XSum, IndoSum, Liputan6 |
| Pelatihan | Fine-tuning dengan cross-entropy (teacher forcing); AdamW; beam search saat inferensi; batasi panjang masukan |
| Metrik | BLEU, chrF, ROUGE, METEOR, BERTScore, penilaian manusia |
| Jebakan | Hanya mengandalkan metrik tumpang-tindih kata; halusinasi fakta; data uji bocor ke data pra-latih |

### H12 · Pelabelan token (NER, POS tagging)

Supervised

| | |
|---|---|
| Baseline | BiLSTM-CRF |
| Arsitektur | BERT, IndoBERT, XLM-RoBERTa untuk token classification |
| Lanjutan | Kepala CRF di atas Transformer; span-based NER; LLM dengan keluaran terstruktur |
| Dataset | CoNLL-2003, OntoNotes 5.0, WikiANN, NERGrit dan POSP (IndoNLU) |
| Pelatihan | Skema BIO; selaraskan label dengan subword; AdamW dengan learning rate 2e-5 sampai 5e-5; 3-10 epoch |
| Metrik | Precision, recall, F1 tingkat entitas (seqeval) |
| Jebakan | F1 dihitung per token (seharusnya per entitas); kalimat dari dokumen yang sama di latih dan uji |

### H13 · Klasifikasi teks dengan sedikit label

Few-shot / transfer learning

| | |
|---|---|
| Baseline | TF-IDF + Logistic Regression |
| Arsitektur | SetFit (sentence-transformers + contrastive), embedding beku + classifier |
| Lanjutan | LLM zero-shot/few-shot dengan prompt; augmentasi data dengan LLM |
| Dataset | Data sendiri; simulasi few-shot pada SST-2, AG News, IndoNLU |
| Pelatihan | 8-64 contoh per kelas; contrastive fine-tuning pasangan kalimat; ulangi dengan beberapa sampel few-shot berbeda |
| Metrik | Accuracy dan macro-F1, dilaporkan sebagai rata-rata ± simpangan baku antar-sampel |
| Jebakan | Varians sangat tinggi antar-sampel few-shot; prompt ditala pada data uji |

### H14 · Klasifikasi teks dengan fine-tuning Transformer

Supervised

| | |
|---|---|
| Baseline | TF-IDF + SVM; TextCNN atau BiLSTM |
| Arsitektur | BERT, RoBERTa, IndoBERT, XLM-RoBERTa, DistilBERT |
| Lanjutan | DeBERTa, domain-adaptive pretraining, LLM dengan LoRA, ensemble |
| Dataset | IMDb, SST-2, AG News, IndoNLU (SmSA, EmoT), IndoLEM |
| Pelatihan | AdamW, learning rate 2e-5 sampai 5e-5, 3-5 epoch, warmup, panjang maksimum 128-512 token; pembersihan ringan tanpa stemming |
| Metrik | Accuracy, precision, recall, macro-F1; rata-rata beberapa seed |
| Jebakan | Stemming dan stopword removal merusak masukan Transformer; satu seed saja; duplikat teks antar-split |

### H15 · Pengenalan ucapan (speech to text)

Supervised / pra-latih

| | |
|---|---|
| Baseline | Whisper pra-latih tanpa pelatihan ulang |
| Arsitektur | wav2vec 2.0 atau HuBERT + CTC; Conformer |
| Lanjutan | Fine-tuning Whisper; penambahan language model; adaptasi aksen/domain |
| Dataset | LibriSpeech, Mozilla Common Voice (ada bahasa Indonesia), FLEURS, TED-LIUM |
| Pelatihan | Audio 16 kHz; CTC loss atau seq2seq cross-entropy; SpecAugment; normalisasi teks transkrip |
| Metrik | Word Error Rate (WER), Character Error Rate (CER), real-time factor |
| Jebakan | Penutur yang sama di latih dan uji; normalisasi teks berbeda antara referensi dan hipotesis |

### H16 · Klasifikasi audio / sinyal

Supervised

| | |
|---|---|
| Baseline | MFCC + SVM; CNN 2D kecil pada spektrogram |
| Arsitektur | CNN pada log-mel spectrogram, CRNN, 1D-CNN pada sinyal mentah |
| Lanjutan | Audio Spectrogram Transformer (AST), PANNs, embedding wav2vec 2.0/HuBERT |
| Dataset | ESC-50, UrbanSound8K, AudioSet, Speech Commands; PhysioNet MIT-BIH (EKG), CWRU Bearing, UCI HAR |
| Pelatihan | Segmentasi jendela; log-mel spectrogram; augmentasi (time shift, noise, SpecAugment, MixUp); pembagian per subjek/rekaman |
| Metrik | Accuracy, macro-F1, sensitivitas dan spesifisitas (medis) |
| Jebakan | Jendela dari rekaman yang sama masuk ke latih dan uji sehingga akurasi semu sangat tinggi |

### H17 · Graph neural network

Supervised / semi-supervised pada graf

| | |
|---|---|
| Baseline | MLP pada fitur node; node2vec + Logistic Regression |
| Arsitektur | GCN, GraphSAGE, GAT, GIN |
| Lanjutan | Graph Transformer, GNN heterogen (R-GCN, HAN), GNN temporal (TGN) |
| Dataset | Cora, CiteSeer, PubMed, Open Graph Benchmark, Reddit, MoleculeNet/QM9, Elliptic |
| Pelatihan | 2-3 lapisan message passing; dropout; neighbor sampling untuk graf besar; untuk link prediction sembunyikan edge uji |
| Metrik | Node: accuracy, macro-F1. Link: ROC-AUC, Hits@k, MRR. Graf: accuracy atau MAE |
| Jebakan | Edge uji terlihat saat pelatihan; over-smoothing pada GNN yang terlalu dalam |

### H18 · Peramalan horizon panjang / multivariat

Supervised pada deret waktu

| | |
|---|---|
| Baseline | Seasonal naive, ARIMA, DLinear |
| Arsitektur | PatchTST, Temporal Fusion Transformer, N-BEATS, N-HiTS, Informer, Autoformer |
| Lanjutan | iTransformer, TimesNet, model fondasi (Chronos, TimesFM, Moirai) |
| Dataset | ETT (ETTh1, ETTm1), Electricity, Traffic, Weather, M4, M5 |
| Pelatihan | Jendela masukan (look-back) dan horizon ditetapkan dulu; normalisasi per deret di-fit pada data latih; loss MSE/MAE atau quantile; split kronologis |
| Metrik | MAE, MSE/RMSE, sMAPE, MASE; CRPS untuk probabilistik |
| Jebakan | Tidak dibandingkan dengan model linear sederhana (sering menang); data diacak; fitur masa depan bocor |

### H19 · Peramalan horizon pendek

Supervised pada deret waktu

| | |
|---|---|
| Baseline | Naive, ARIMA/SARIMA, Exponential Smoothing |
| Arsitektur | LSTM, GRU, TCN, CNN-LSTM |
| Lanjutan | Seq2seq + attention, DeepAR (probabilistik), hibrida ARIMA-LSTM |
| Dataset | Air Passengers, M4, data harga saham (Yahoo Finance), data BPS, BMKG, beban listrik |
| Pelatihan | Jendela geser; scaling di-fit pada data latih; loss MSE/Huber; Adam; early stopping; rolling-origin evaluation |
| Metrik | MAE, RMSE, MAPE/sMAPE, MASE |
| Jebakan | Mengacak data sebelum split; prediksi hanya 'menggeser' nilai terakhir; tidak dibandingkan dengan naive |

### H20 · Klasifikasi deret waktu

Supervised pada deret waktu

| | |
|---|---|
| Baseline | 1-NN DTW; MiniRocket |
| Arsitektur | 1D-CNN, FCN, ResNet 1D, LSTM/GRU, InceptionTime |
| Lanjutan | Transformer deret waktu (TST, PatchTST), pra-latih kontrastif (TS2Vec) |
| Dataset | UCR/UEA Archive, UCI HAR, WISDM, PhysioNet |
| Pelatihan | Segmentasi jendela; normalisasi z per deret; cross-entropy; Adam; pembagian per subjek |
| Metrik | Accuracy, macro-F1, confusion matrix |
| Jebakan | Jendela bertumpang-tindih dari subjek yang sama di latih dan uji |

### H21 · Deep learning untuk data tabular

Supervised

| | |
|---|---|
| Baseline | XGBoost/LightGBM/CatBoost (pembanding wajib); MLP |
| Arsitektur | MLP dengan embedding kategori, TabNet, FT-Transformer, ResNet tabular |
| Lanjutan | SAINT, TabTransformer, pra-latih self-supervised (SCARF), ensemble DL + boosting |
| Dataset | Covertype, Higgs, Adult, California Housing, benchmark OpenML (CC18, TabZilla) |
| Pelatihan | Standardisasi atau quantile transform fitur numerik; embedding untuk kategori; AdamW; weight decay; early stopping; tuning dengan Optuna |
| Metrik | Klasifikasi: accuracy, F1, ROC-AUC. Regresi: MAE, RMSE, $R^2$ |
| Jebakan | Mengklaim unggul tanpa membandingkan dengan gradient boosting yang ditala dengan baik |

### H22 · Data tabular kecil: deep learning bukan pilihan utama

Supervised (machine learning klasik)

| | |
|---|---|
| Baseline | Logistic/Linear Regression |
| Arsitektur | Random Forest, XGBoost, LightGBM, CatBoost |
| Lanjutan | TabPFN (model pra-latih untuk tabel kecil), stacking |
| Dataset | UCI Adult, Breast Cancer Wisconsin, Pima Diabetes, data sendiri |
| Pelatihan | Gunakan machine learning klasik dengan cross validation; bila tetap ingin deep learning, pakai MLP kecil dengan regularisasi kuat sebagai pembanding |
| Metrik | Klasifikasi: F1, ROC-AUC, MCC. Regresi: MAE, RMSE |
| Jebakan | Memaksakan deep learning pada ratusan baris data; overfitting; hasil tidak stabil antar-seed |

### H23 · Deep RL dengan aksi kontinu

Reinforcement learning

| | |
|---|---|
| Baseline | Kebijakan acak, pengendali PID, REINFORCE |
| Arsitektur | PPO, SAC, TD3, DDPG |
| Lanjutan | Dreamer, MBPO, sim-to-real dengan domain randomization |
| Dataset | Lingkungan: MuJoCo (Gymnasium), DeepMind Control Suite, PyBullet, Isaac Lab |
| Pelatihan | Rancang observasi, aksi, reward; normalisasi observasi dan reward; replay buffer (off-policy); 5-10 seed |
| Metrik | Average return, sample efficiency, tingkat keberhasilan, interquartile mean |
| Jebakan | Satu seed saja; reward shaping menghasilkan perilaku tak diinginkan; hasil simulator tidak berpindah ke dunia nyata |

### H24 · Deep RL dengan aksi diskret

Reinforcement learning

| | |
|---|---|
| Baseline | DQN |
| Arsitektur | Double DQN, Dueling DQN, Rainbow, A2C, PPO |
| Lanjutan | MuZero, IMPALA, multi-agent (QMIX, MAPPO) |
| Dataset | Lingkungan: CartPole, LunarLander, Atari (ALE), MiniGrid, PettingZoo, SUMO |
| Pelatihan | Replay buffer, target network, epsilon-greedy yang menurun; frame stacking; minimal 5 seed |
| Metrik | Average return, human-normalized score, sample efficiency |
| Jebakan | Pelatihan tidak stabil dan sensitif hyperparameter; lingkungan uji sama persis dengan lingkungan latih |

### H25 · Generasi teks dengan LLM

Generative AI

| | |
|---|---|
| Baseline | GPT-2 fine-tuning; LLM dengan prompt tanpa pelatihan |
| Arsitektur | LLM terbuka (Llama, Mistral, Qwen, Gemma) dengan LoRA/QLoRA |
| Lanjutan | Instruction tuning, RAG, agen dengan tool, distilasi ke model kecil |
| Dataset | WikiText-103, OpenWebText, dataset instruksi (Alpaca, Dolly), korpus domain sendiri |
| Pelatihan | Format instruksi-jawaban; LoRA rank 8-64; quantization 4-bit saat pelatihan; AdamW; pantau loss validasi |
| Metrik | Perplexity, BLEU/ROUGE, BERTScore, penilaian manusia, penilaian LLM-as-judge dengan rubrik |
| Jebakan | Halusinasi; data uji ada di data pra-latih; evaluasi hanya dengan metrik otomatis |

### H26 · Generasi citra dengan diffusion

Generative AI

| | |
|---|---|
| Baseline | VAE atau DCGAN |
| Arsitektur | DDPM, DDIM, Latent Diffusion / Stable Diffusion |
| Lanjutan | LoRA, DreamBooth, ControlNet, classifier-free guidance, consistency models |
| Dataset | CIFAR-10, CelebA-HQ, FFHQ, LSUN, ImageNet, LAION (teks ke citra) |
| Pelatihan | Fine-tuning model pra-latih lebih realistis daripada melatih dari nol; noise-prediction loss (MSE); EMA bobot; mixed precision |
| Metrik | FID, KID, Inception Score, CLIP score, precision/recall generatif |
| Jebakan | FID bias pada sampel sedikit; model menghafal data latih; isu hak cipta dan etika |

### H27 · Translasi citra ke citra

Generative AI

| | |
|---|---|
| Baseline | U-Net dengan loss L1 |
| Arsitektur | Pix2Pix (data berpasangan), CycleGAN (tidak berpasangan) |
| Lanjutan | Pix2PixHD, SPADE, ControlNet / InstructPix2Pix (diffusion) |
| Dataset | Cityscapes, Facades, Maps, horse2zebra; pasangan citra medis (MRI ke CT) |
| Pelatihan | Adversarial loss + L1 (Pix2Pix) atau cycle-consistency loss (CycleGAN); Adam (lr 2e-4, beta1 0.5); PatchGAN discriminator |
| Metrik | FID, SSIM, PSNR, LPIPS; penilaian manusia atau ahli |
| Jebakan | Artefak dan halusinasi struktur (berbahaya pada citra medis); mode collapse |

### H28 · Generasi citra dengan GAN / VAE

Generative AI

| | |
|---|---|
| Baseline | VAE |
| Arsitektur | DCGAN, WGAN-GP, conditional GAN |
| Lanjutan | StyleGAN2/3 (dengan ADA untuk data sedikit), VQ-VAE |
| Dataset | MNIST, CIFAR-10, CelebA, FFHQ, LSUN |
| Pelatihan | Normalisasi citra ke [-1, 1]; Adam (lr 2e-4, beta1 0.5); seimbangkan generator dan discriminator; spectral normalization |
| Metrik | FID, KID, Inception Score, precision/recall generatif |
| Jebakan | Mode collapse; pelatihan tidak konvergen; FID dihitung terhadap data latih saja |

### H29 · Data sintetis tabular / deret waktu

Generative AI

| | |
|---|---|
| Baseline | SMOTE atau Gaussian Copula |
| Arsitektur | CTGAN, TVAE; TimeGAN (deret waktu) |
| Lanjutan | TabDDPM, TabSyn, model berbasis LLM (GReaT) |
| Dataset | Adult, Covertype, Credit Default; data sendiri yang sensitif |
| Pelatihan | Tandai tipe kolom; mode-specific normalization (CTGAN); latih hanya pada data latih; simpan data uji asli |
| Metrik | Fidelity (uji KS, selisih korelasi), utility (train on synthetic, test on real), privasi (distance to closest record) |
| Jebakan | Data sintetis menyalin baris asli; relasi antar-kolom rusak |

### H30 · Deteksi anomali deret waktu dengan deep learning

Unsupervised

| | |
|---|---|
| Baseline | Rolling z-score; Isolation Forest pada fitur jendela |
| Arsitektur | LSTM Autoencoder, galat prediksi LSTM, USAD |
| Lanjutan | OmniAnomaly, Anomaly Transformer, TranAD |
| Dataset | NAB, Yahoo S5, SMD, SMAP/MSL, SWaT/WADI, UCR Anomaly Archive |
| Pelatihan | Latih pada periode normal; jendela geser; skor anomali = galat rekonstruksi/prediksi; ambang dari data validasi; split kronologis |
| Metrik | PR-AUC, F1 berbasis rentang, VUS, keterlambatan deteksi; laporkan F1 dengan dan tanpa point adjustment |
| Jebakan | Point adjustment membuat skor tampak tinggi; benchmark dengan anomali terlalu mudah |

### H31 · Deteksi anomali dengan deep learning

Unsupervised / one-class

| | |
|---|---|
| Baseline | Isolation Forest, One-Class SVM (pembanding wajib) |
| Arsitektur | Autoencoder, Variational Autoencoder, Deep SVDD, DAGMM |
| Lanjutan | GANomaly, PatchCore dan PaDiM (citra), federated autoencoder |
| Dataset | NSL-KDD, UNSW-NB15, CIC-IDS2017, N-BaIoT, IoT-23, Credit Card Fraud; citra: MVTec AD |
| Pelatihan | Latih hanya pada data normal; loss rekonstruksi (MSE); bottleneck sempit; ambang dari persentil galat pada data validasi |
| Metrik | ROC-AUC, PR-AUC, F1 pada ambang terpilih, false positive rate |
| Jebakan | Ambang ditala pada data uji; autoencoder terlalu besar sehingga anomali pun terekonstruksi baik |

### H32 · Deep clustering

Unsupervised

| | |
|---|---|
| Baseline | K-Means pada fitur asli atau hasil PCA |
| Arsitektur | Autoencoder + K-Means, Deep Embedded Clustering (DEC), IDEC |
| Lanjutan | DeepCluster, SCAN, clustering pada embedding pra-latih (DINOv2, sentence embedding) |
| Dataset | MNIST, Fashion-MNIST, CIFAR-10, STL-10, Reuters-10k |
| Pelatihan | Pra-latih autoencoder; inisialisasi pusat klaster dengan K-Means; loss KL divergence + rekonstruksi |
| Metrik | Clustering accuracy (ACC), NMI, ARI; silhouette bila tanpa label |
| Jebakan | Solusi trivial (semua data ke satu klaster); hasil sensitif terhadap inisialisasi |

### H33 · Autoencoder untuk reduksi dimensi / representasi

Unsupervised

| | |
|---|---|
| Baseline | PCA |
| Arsitektur | Autoencoder, Denoising Autoencoder, Sparse Autoencoder |
| Lanjutan | Variational Autoencoder, VQ-VAE, Masked Autoencoder |
| Dataset | MNIST, Fashion-MNIST, data ekspresi gen, data trafik jaringan |
| Pelatihan | Loss rekonstruksi (MSE atau BCE); ukuran bottleneck sebagai hyperparameter utama; evaluasi dengan tugas hilir |
| Metrik | Galat rekonstruksi; performa model hilir pada representasi laten |
| Jebakan | Autoencoder hanya menyalin masukan (bottleneck terlalu lebar); tidak dibandingkan dengan PCA |

### H34 · Pra-pelatihan self-supervised

Self-supervised

| | |
|---|---|
| Baseline | Model supervised dari nol; model pra-latih umum (ImageNet) |
| Arsitektur | SimCLR, MoCo, BYOL, DINO, MAE (citra); masked language modeling (teks); wav2vec 2.0 (audio); TS2Vec (deret waktu) |
| Lanjutan | Pra-pelatihan lanjutan pada data domain; CLIP; model fondasi |
| Dataset | ImageNet, CIFAR-10/100, STL-10; korpus domain tak berlabel berukuran besar |
| Pelatihan | Rancang augmentasi atau masking sesuai jenis data; batch besar atau momentum encoder; InfoNCE atau loss rekonstruksi; pelatihan panjang |
| Metrik | Linear probing, fine-tuning dengan 1%/10% label, akurasi kNN pada embedding |
| Jebakan | Representation collapse; augmentasi merusak informasi penting; butuh komputasi besar |

### H35 · Deep learning mungkin tidak diperlukan

Perlu perumusan ulang

| | |
|---|---|
| Baseline | Exploratory data analysis |
| Arsitektur | Rumuskan ulang masukan, keluaran, dan ukuran keberhasilan; gunakan peta keputusan machine learning umum |
| Lanjutan | Bila masalahnya optimasi (penjadwalan, rute): metaheuristik atau pemrograman matematis |
| Dataset | Belum dapat ditentukan |
| Pelatihan | Belum dapat ditentukan |
| Metrik | Belum dapat ditentukan |
| Jebakan | Memaksakan deep learning pada masalah yang cukup diselesaikan dengan aturan, statistik, atau machine learning klasik |

## Pertanyaan kondisi khusus (ya/tidak) setelah hasil ditemukan

### Data sedikit

*Apakah data latih Anda sedikit? Jika ya:*

- Gunakan transfer learning dari model pra-latih; jangan melatih dari nol.
- Augmentasi data (citra: flip, crop, MixUp; teks: back-translation; audio: SpecAugment).
- Pertimbangkan few-shot learning atau data sintetis.
- Validasi dengan k-fold berulang dan laporkan selang kepercayaan.

### Kelas tidak seimbang

*Apakah jumlah data antarkelas sangat timpang? Jika ya:*

- Gunakan class-weighted cross-entropy atau focal loss.
- Oversampling kelas minoritas atau weighted sampler pada data latih saja.
- Laporkan macro-F1, PR-AUC, dan recall per kelas, bukan hanya accuracy.
- Tala ambang keputusan pada data validasi.

### Overfitting

*Apakah akurasi latih jauh lebih tinggi daripada akurasi validasi? Jika ya:*

- Tambahkan dropout, weight decay, dan augmentasi data.
- Gunakan early stopping dan kecilkan kapasitas model.
- Tambah data atau pakai model pra-latih.
- Periksa kebocoran data antar-split.

### Pelatihan tidak stabil

*Apakah loss naik-turun tajam, menjadi NaN, atau tidak turun? Jika ya:*

- Turunkan learning rate; pakai warmup dan cosine schedule.
- Gunakan gradient clipping dan normalisasi (batch/layer norm).
- Periksa normalisasi masukan dan inisialisasi bobot.
- Uji dulu pada subset kecil: model harus bisa overfit pada satu batch.

### Butuh penjelasan (XAI)

*Apakah keputusan model harus dapat dijelaskan? Jika ya:*

- Citra: Grad-CAM, Score-CAM, Integrated Gradients.
- Teks: atribusi token (Integrated Gradients, SHAP), attention rollout.
- Tabular/deret waktu: SHAP (DeepExplainer, KernelExplainer).
- Evaluasi penjelasan (uji deletion/insertion) dan validasi dengan ahli domain.

### Perangkat terbatas

*Apakah model harus berjalan di perangkat terbatas atau real-time? Jika ya:*

- Pilih arsitektur ringan (MobileNet, DistilBERT, TinyML).
- Quantization (INT8), pruning, knowledge distillation.
- Ekspor ke ONNX Runtime, TensorFlow Lite, atau TensorRT.
- Laporkan ukuran model, latensi, memori, dan energi pada perangkat sasaran.

### Data terdistribusi dan privat

*Apakah data tersebar di banyak pihak dan tidak boleh dikumpulkan? Jika ya:*

- Federated learning: FedAvg sebagai baseline; FedProx atau SCAFFOLD untuk data non-IID.
- Simulasikan partisi non-IID (Dirichlet) dan laporkan pengaruhnya.
- Tambahkan differential privacy (DP-SGD) atau secure aggregation bila privasi diklaim.
- Laporkan ronde dan biaya komunikasi; pustaka: Flower, FedML.

### Kuantifikasi ketidakpastian

*Apakah Anda memerlukan ukuran keyakinan dari setiap prediksi? Jika ya:*

- MC Dropout atau deep ensemble.
- Kalibrasi dengan temperature scaling; ukur ECE dan reliability diagram.
- Conformal prediction untuk himpunan atau interval prediksi.
- Evidential deep learning bila perlu satu kali forward pass.

### Komputasi terbatas

*Apakah Anda tidak memiliki GPU yang memadai? Jika ya:*

- Gunakan model pra-latih sebagai pengekstrak fitur beku, lalu latih kepala ringan.
- Mixed precision, batch kecil dengan gradient accumulation, LoRA/QLoRA untuk LLM.
- Manfaatkan Google Colab atau Kaggle Notebooks.
- Kecilkan resolusi masukan dan mulai dari subset data.

Rekomendasi adalah titik awal. Periksa literatur terbaru pada topik Anda sebelum menetapkan metode.

# Taksonomi Deep Learning

Peta pikiran dari fondasi jaringan sampai keluarga arsitektur, strategi pelatihan, keandalan, dan deployment.

Setiap warna adalah satu cabang utama. Semakin jauh dari pusat, semakin spesifik (kategori, lalu algoritma atau teknik).

