

# Deep Learning dan Jaringan Syaraf Lanjutan

## A. Perbedaan ANN dan Deep Learning

### 1. Artificial Neural Network (ANN): Konsep Dasar

Artificial Neural Network (ANN) adalah model komputasi yang terinspirasi dari cara kerja neuron biologis. ANN biasanya terdiri dari tiga jenis layer:

- Input layer
- Hidden layer (biasanya 1 layer)
- Output layer

ANN mampu mempelajari pola sederhana hingga menengah, tetapi memiliki keterbatasan ketika masalah semakin kompleks, misalnya citra resolusi tinggi, bahasa alami, atau data berdimensi besar. ANN tradisional kurang efisien dalam mengekstraksi fitur secara otomatis.

### 2. Deep Learning: ANN dalam Skala Lebih Dalam

Deep Learning adalah pengembangan ANN dengan jumlah hidden layer yang jauh lebih banyak (*deep architecture*). Setiap layer mempelajari representasi data yang semakin abstrak, sehingga deep learning mampu mengolah data berskala besar dan kompleks secara otomatis tanpa perlu rekayasa fitur manual.

Ciri khas Deep Learning:

- Menggunakan network bertingkat (deep neural networks).
- Mampu feature learning otomatis.
- Performa sangat baik untuk data citra, audio, teks, dan deret waktu.



### 3. Perbandingan ANN vs Deep Learning

#### a. Struktur Arsitektur

Aspek	ANN	Deep Learning
Jumlah hidden layer	1–2	Banyak (lebih dari 3 hingga ratusan)
Kompleksitas model	Rendah–sedang	Tinggi
Kemampuan representasi	Terbatas	Sangat tinggi

#### b. Pemrosesan Fitur

- ANN membutuhkan *feature engineering* manual.
- Deep Learning melakukan *automatic feature extraction*.

Contoh:

- ANN butuh fitur tepi atau kontras saat mengolah citra.
- CNN (jenis deep learning) otomatis mendeteksi tepi, pola, bentuk, objek.

#### c. Kebutuhan Data

- ANN dapat bekerja dengan dataset kecil hingga menengah.
- Deep Learning membutuhkan dataset besar untuk performa optimal.

#### d. Kebutuhan Komputasi

- ANN ringan, dapat dilatih tanpa GPU.
- Deep Learning sangat intensif komputasi—butuh GPU/TPU.

#### e. Jenis Masalah

- ANN cocok untuk prediksi sederhana, regresi, klasifikasi tabular.
- Deep Learning unggul dalam:
  - pengenalan citra (CNN),
  - pemrosesan bahasa alami (RNN/LSTM/Transformer),
  - prediksi deret waktu yang kompleks,
  - suara, video, sinyal sensor.



#### 4. Ilustrasi Tingkat Abstraksi

Dalam Deep Learning:

- Layer awal → mendeteksi fitur dasar (edge, garis, sudut).
- Layer tengah → mendeteksi pola lebih kompleks (bentuk, tekstur).
- Layer akhir → memahami konsep objek (mobil, wajah, huruf).

Sedangkan ANN tradisional tidak memiliki kemampuan hierarki fitur sedalam itu.

#### 5. Kapan Menggunakan ANN vs Deep Learning

Gunakan ANN jika:

- Dataset kecil.
- Masalah sederhana (prediksi IPK, klasifikasi diabetes, regresi numerik).
- Hardware terbatas.

Gunakan Deep Learning jika:

- Data bersifat visual, teks, audio.
- Butuh akurasi tinggi pada pola sangat kompleks.
- Memiliki cukup data dan komputasi.

### B. Arsitektur CNN dan RNN secara Konseptual

#### 1. Convolutional Neural Network (CNN)

CNN adalah arsitektur deep learning yang dirancang khusus untuk memproses data berstruktur grid, seperti:

- Citra (image) 2D,
- Video (image sequence),
- Sinyal 1D (jika diperlukan).

CNN unggul karena mampu belajar fitur spasial secara otomatis seperti pola bentuk, tekstur, dan objek.



## Konsep Dasar Arsitektur CNN

### a. Convolution Layer (Lapisan Konvolusi)

Merupakan inti dari CNN. Lapisan ini menggunakan filter/kernel yang bergerak melintasi citra untuk mengekstraksi fitur penting.

Fungsi utama:

- Mendapatkan pola sederhana seperti tepi, garis, sudut.
- Menghasilkan *feature map* (peta fitur) sebagai representasi awal citra.

Proses konvolusi:

1. Filter berukuran kecil (misal 3×3) ditempelkan pada citra.
2. Digeser dari kiri ke kanan dan atas ke bawah.
3. Setiap posisi menghasilkan nilai baru.

### b. Activation Layer (ReLU)

Umumnya CNN menggunakan fungsi aktivasi ReLU untuk:

- Menambahkan non-linearitas,
- Mempercepat pelatihan,
- Menghindari vanishing gradient.

Contoh:

$$\text{ReLU}(x) = \max(0, x)$$

### c. Pooling Layer

Pooling bertujuan untuk mengurangi dimensi feature map tetapi tetap mempertahankan informasi penting.

Jenis umum:

- Max Pooling mengambil nilai terbesar dalam jendela.
- Average Pooling menghitung rata-rata.

Manfaat:

- Mengurangi ukuran data,
- Mengurangi kompleksitas komputasi,
- Mengurangi risiko overfitting.



#### d. Fully Connected Layer (FC Layer)

Pada bagian akhir arsitektur CNN, hasil ekstraksi fitur diubah menjadi vektor 1D dan diteruskan ke jaringan multilayer perceptron untuk melakukan:

- Klasifikasi objek,
- Prediksi kelas.

#### e. Softmax Layer

Jika CNN digunakan untuk klasifikasi, layer terakhir biasanya Softmax agar menghasilkan probabilitas kelas.

### Alur Konseptual CNN

Citra → Convolution → ReLU → Pooling → (Ulangi beberapa kali) → Fully Connected Layer → Softmax → Prediksi

CNN belajar dari fitur paling dasar hingga kompleks:

- Layer awal: tepi dan garis
- Layer tengah: pola tekstur
- Layer akhir: objek (wajah, mobil, hewan)

## 2. Recurrent Neural Network (RNN)

RNN adalah arsitektur deep learning yang dirancang untuk memproses data berurutan (*sequential*), seperti:

- Teks (kalimat, paragraf),
- Data log atau sensor,
- Sinyal suara,
- Deret waktu (time series): cuaca, harga saham, trafik jaringan.

Berbeda dari CNN yang fokus pada pola spasial, RNN menangkap pola dependensi temporal, yaitu hubungan antar data dalam urutan waktu.



## Konsep Dasar Arsitektur RNN

### a. Struktur RNN

RNN memiliki unit dasar yang menerima dua input:

1. Input saat ini ( $x_t$ ),
2. Informasi dari waktu sebelumnya ( $h_{t-1}$ ) → disebut *hidden state*.

Hidden state menyimpan memori jangka pendek sehingga jaringan dapat memahami konteks urutan.

Rumus dasar:

$$h_t = f(W_h h_{t-1} + W_x x_t + b)$$

Artinya:

- Output saat ini dipengaruhi oleh input sekarang dan keadaan sebelumnya.

### b. Backpropagation Through Time (BPTT)

Pelatihan RNN dilakukan dengan memanjangkan urutan waktu ke belakang.

Namun ini sering menyebabkan:

- Vanishing gradient
- Exploding gradient

Masalah ini melahirkan varian RNN yang lebih stabil.

### c. LSTM dan GRU (RNN Modern)

Untuk mengatasi kelemahan RNN, dikembangkan arsitektur:

- LSTM (Long Short-Term Memory)
- GRU (Gated Recurrent Unit)

Keduanya menggunakan mekanisme gate (gerbang) untuk:

- Menyimpan informasi penting,
- Membuang informasi yang tidak relevan,
- Mengingat konteks jangka panjang.

Berkat gate mechanism ini, LSTM dan GRU lebih unggul untuk:

- Analisis sentimen,
- Prediksi deret waktu,



- Terjemahan bahasa,
- Speech recognition.

### Alur Konseptual RNN

Urutan data  $\rightarrow (x_1 \rightarrow x_2 \rightarrow x_3 \rightarrow \dots)$

Pada tiap langkah:

$x_t + h_{t-1} \rightarrow$  menghasilkan  $\rightarrow h_t \rightarrow$  menentukan output  $\rightarrow$  diteruskan ke langkah berikutnya.

Secara sederhana:

Input 1  $\rightarrow$  Output 1  $\rightarrow$

Input 2 + memori Output 1  $\rightarrow$  Output 2  $\rightarrow$

Input 3 + memori Output 2  $\rightarrow$  Output 3  $\rightarrow \dots$

Iniilah sebabnya RNN “ingat” konteks sebelumnya.

### Perbandingan Konseptual CNN vs RNN

Aspek	CNN	RNN
Jenis data	Spasial (gambar, video)	Berurutan (teks, deret waktu, suara)
Cara belajar	Fitur ruang / pola visual	Fitur waktu / pola urutan
Kelebihan	Efektif untuk citra, objek, pola visual	Efektif untuk konteks, urutan, dan prediksi
Mekanisme inti	Convolution + Pooling	Hidden state + recurrent loop
Contoh aplikasi	Deteksi wajah, klasifikasi objek	Prediksi harga, analisis sentimen, speech-to-text

