

Pengantar Analisis Deret Waktu dalam Teknik Elektro

Karakteristik Data, Komponen Sinyal, dan Dekomposisi Temporal

Ir. Novalio Daratha, S.T., M.Sc., Ph.D.

Program Studi Teknik Elektro – Fakultas Teknik
Universitas Bengkulu

Minggu 1 / Semester Ganjil 2026

Agenda Perkuliahan Minggu ke-1

Capaian Pembelajaran (Sub-CPMK 1)

Mahasiswa mampu mengidentifikasi karakteristik data temporal sistem kelistrikan, membedakan tipe dependensi waktu, serta melakukan dekomposisi komponen data secara komputasional.

- ① Urgensi Deret Waktu di Teknik Elektro
- ② Definisi & Notasi Matematis
- ③ 4 Komponen Utama Sinyal Temporal
- ④ Model Dekomposisi: Aditif vs Multiplikatif
- ⑤ Tantangan Data Riil Sistem Tenaga
- ⑥ Hands-on Komputasi (Python / Octave)

Mengapa Analisis Deret Waktu Krusial di Teknik Elektro?

1. Operasi & Perencanaan Sistem Tenaga

- **Load Forecasting:** Peramalan beban puncak untuk menjamin *spinning reserve* dan stabilitas tegangan.
- **Economic Dispatch:** Menentukan pembangkit paling ekonomis setiap jam.

2. Integrasi Energi Terbarukan (EBT)

- Pembangkitan PLTS (intermitensi radiasi matahari) dan PLTB (kecepatan angin) bersifat stokastik.

3. Smart Grid & Telemetri IoT

- Jutaan data *Smart Meter* per detik: deteksi pencurian daya & anomali beban.

4. Diagnostik Mesin & Proteksi

- Sinyal getaran bantalan motor, deret waktu gas DGA pada trafo, dan harmonisa arus.

Definisi Matematis Deret Waktu

Definisi Formal

Deret waktu (*Time Series*) adalah himpunan observasi berurutan yang dicatat secara kronologis pada interval waktu diskrit yang teratur $t \in \mathcal{T}$:

$$\{X_t\} = \{X_1, X_2, X_3, \dots, X_N\} \quad \text{atau} \quad X(t), \quad t = 1, 2, \dots, N \quad (1)$$

Ciri Khas vs Data Tabular Standar:

- **Autokorelasi:** X_t tidak independen dari X_{t-1}, X_{t-2} .
- **Sensitivitas Urutan:** Pengacakan baris data (*shuffling*) akan merusak struktur informasi fisiknya.

Frekuensi Pencatatan Elektro:

- Sub-detik (milidetik): PMU (*Phasor Measurement Unit*).
- Menitan: Inverter PLTS, Sensor IoT.
- Per-jam: Profil beban harian PLN.

4 Komponen Pembentuk Sinyal Deret Waktu

Secara klasik, setiap deret waktu y_t tersusun dari empat komponen dinamis:

1. Tren (T_t) - Long-Term Direction

Kecenderungan arah data dalam jangka panjang (naik/turun) akibat pertumbuhan ekonomi, penambahan pelanggan industri, atau populasi.

3. Siklus (C_t) - Cyclical Pattern

Osilasi naik-turun yang durasinya tidak tetap (misal siklus resesi ekonomi atau fluktuasi multi-tahunan fenomena El-Niño).

2. Musiman (S_t) - Seasonality

Fluktuasi periodik yang berulang pada frekuensi tetap (harian: jam beban puncak 18.00–22.00, mingguan: hari kerja vs libur, tahunan: cuaca kemarau/hujan).

4. Residu / Derau (R_t / ϵ_t)

Komponen acak tak terduga (*white noise*) yang disebabkan oleh gangguan acak, sambaran petir, atau padamnya beban tiba-tiba.

Model Dekomposisi Sinyal: Aditif vs Multiplikatif

Model Aditif (*Additive Model*)

$$y_t = T_t + S_t + R_t \quad (2)$$

Karakteristik:

- Magnitudo variasi musiman (S_t) **konstan** terlepas dari naiknya nilai tren T_t .
- Cocok jika beban puncak naik stabil setiap tahun tanpa peningkatan lebar osilasi.

Model Multiplikatif (*Multiplicative Model*)

$$y_t = T_t \times S_t \times R_t \quad (3)$$

Karakteristik:

- Variasi musiman **proporsional** terhadap level tren (semakin tinggi tren, semakin lebar fluktuasi beban).
- Sering ditemui pada sistem distribusi yang bertumbuh pesat.

Transformasi Logaritmik

Model multiplikatif dapat diubah menjadi model aditif via transformasi log:

$$\ln(y_t) = \ln(T_t) + \ln(S_t) + \ln(R_t).$$

Metode Dekomposisi Klasik Berbasis Moving Average

Bagaimana mengekstraksi komponen T_t , S_t , dan R_t dari sinyal mentah y_t ?

- 1 **Estimasi Tren (T_t)** menggunakan filter pemulus berbobot (*Centered Moving Average* dengan panjang jendela m sama dengan periode musiman, misal $m = 24$ untuk data per-jam):

$$\hat{T}_t = \frac{1}{m} \left(\frac{1}{2}y_{t-m/2} + y_{t-m/2+1} + \cdots + y_{t+m/2-1} + \frac{1}{2}y_{t+m/2} \right) \quad (4)$$

- 2 **Detrending (Menghilangkan Tren):**

$$\text{Aditif: } y_t - \hat{T}_t = S_t + R_t \quad \text{Multiplikatif: } y_t / \hat{T}_t = S_t \times R_t \quad (5)$$

- 3 **Estimasi Musiman ($\hat{S}_t$)**: Rata-ratakan nilai hasil detrending untuk setiap periode musiman (misal seluruh pukul 18.00).
- 4 **Isolasi Residu ($\hat{R}_t$)**: Sisa data setelah dikurangi tren dan musiman.

Karakteristik Residual yang Ideal (White Noise)

Komponen residu R_t harus berupa proses **White Noise** jika seluruh pola sinyal telah terekstraksi sempurna:

Syarat Matematis White Noise

- 1 Rata-rata nol: $\mathbb{E}[R_t] = 0$
- 2 Variansi konstan (Homoskedastik):
 $\text{Var}(R_t) = \sigma^2$
- 3 Tidak ada autokorelasi:

$$\gamma(k) = \text{Cov}(R_t, R_{t-k}) = 0 \quad (\forall k \neq 0) \quad (6)$$

Implikasi dalam Rekayasa Elektro

- Jika residu masih memiliki pola berkala $\rightarrow$ Masih ada frekuensi harmonisa atau pola musiman yang terlewat.
- Model peramalan dikatakan **optimal** apabila sisa error tidak dapat diprediksi lagi (murni acak).

Implementasi Komputasi: Dekomposisi dengan Python

```
import pandas as pd
import matplotlib.pyplot as plt
from statsmodels.tsa.seasonal import seasonal_decompose

# 1. Membaca dataset beban listrik PLN / Gardu Induk (Interval: 1 Jam)
df = pd.read_csv('load_data.csv', parse_dates=['timestamp'], index_col='timestamp')

# 2. Melakukan dekomposisi aditif dengan periode musiman harian (period=24 jam)
decomposition = seasonal_decompose(df['power_mw'], model='additive', period=24)

# 3. Mengekstrak masing-masing komponen
trend = decomposition.trend
seasonal = decomposition.seasonal
residual = decomposition.resid

# 4. Plot visualisasi 4-panel
fig = decomposition.plot()
fig.set_size_inches(10, 6)
plt.tight_layout()
plt.show()
```

Tantangan Nyata Data Deret Waktu di Lapangan

1. Multiple Seasonality

Data beban memiliki siklus jam (24 jam), hari (7 hari), dan tahunan (365 hari) yang bertumpuk secara simultan.

2. Outlier & Gangguan

Sambaran petir, pemadaman sebagian (*blackout*), atau kegagalan transmisi menciptakan lonjakan anomali.

3. Missing Values

Data telemetri RTU/SCADA hilang akibat gangguan koneksi komunikasi nirkabel.

*Pra-pemrosesan data (*cleaning*, interpolasi, pemfilteran derau) menyumbang 60% keberhasilan model peramalan!*

Rangkuman dan Rencana Materi Minggu Depan

Takeaways Minggu 1

- Deret waktu adalah urutan data berindeks kronologis dengan dependensi autokorelasi antar observasi.
- Sinyal kelistrikan dapat diurai menjadi 4 komponen: Tren, Musiman, Siklus, dan Residu.
- Dekomposisi mempermudah insinyur mengisolasi fluktuasi periodik dan mengevaluasi kesehatan sistem.

Materi Minggu Depan (Minggu ke-2)

Stasioneritas & Analisis Korelasi Sinyal:

- Menguji kestasioneran data menggunakan *Augmented Dickey-Fuller* (ADF) dan KPSS Test.
- Plot Korelogram: Autocorrelation Function (ACF) & Partial ACF (PACF).
- Teknik Diferensiasi (*Differencing*) untuk menstasionerkan sinyal.

Terima Kasih

Ada pertanyaan atau tanggapan terkait materi hari ini?

Laboratorium Sistem Tenaga & Komputasi Cerdas

Jurusan Teknik Elektro – Fakultas Teknik

Universitas Bengkulu