

## BAB II

### TINJAUAN PUSTAKA

#### 1.1 *Seasonal And Trend Decomposition Using Loess (STL)*

*Seasonal And Trend Decomposition Using Loess* (STL) adalah algoritma yang dirancang untuk menguraikan deret waktu menjadi tiga komponen: tren, kemusiman, dan sisa. Pola musiman mengacu pada fluktuasi data yang terjadi pada interval tertentu dan berulang secara konsisten pada periode berikutnya. Sebaliknya, pola tren menunjukkan arah umum peningkatan atau penurunan data dari waktu ke waktu. Mengidentifikasi pola tren ini penting untuk memperkirakan perubahan di masa mendatang dalam nilai variabel data yang diamati. (Al'afi dkk, 2021).

Algoritma ini menggunakan teknik regresi lokal (LOESS) untuk memperkirakan komponen secara efektif, dengan menjalankan proses dekomposisi secara berulang hingga konvergensi yang diinginkan tercapai. Selain itu, parameter seperti tinggi penempatan jendela dapat dimodifikasi untuk meningkatkan hasil akhir. Hasil dekomposisi selanjutnya divisualisasikan untuk membantu analisis, sementara residu yang dihasilkan digunakan untuk mengidentifikasi anomali, dengan nilai yang menyimpang dari pola yang diharapkan ditafsirkan sebagai indikator potensi masalah. Pola musiman (seasonal) adalah pola dimana kenaikan dan penurunan pergerakan data terjadi pada periode-periode tertentu dan selalu berulang pada periode berikutnya. Sedangkan Pola Trend adalah pola dimana terjadi kecenderungan peningkatan atau penurunan pada pola pergerakan data dan identifikasi pola trend ini digunakan untuk meramal (*Forecasting*) besaran

peningkatan nilai pada variabel data yang diamati pada periode selanjutnya (Al'afi dkk, 2021).

Tujuan dibuatnya metode ini adalah untuk mengembangkan cara pendekomposisian agar pengguna dapat lebih mudah dalam memakai metode ini. Berikut adalah keistimewaan dari metode STL.

1. Desain yang sederhana dan mudah digunakan
2. Fleksibel dalam menentukan jumlah variasi pada komponen trend dan seasonal
3. Spesifikasi jumlah pengamatan tiap satu siklus pada komponen seasonal untuk bilangan bulat lebih besar dari Satu
4. Mampu mendekomposisikan (menguraikan) data- data series yang tidak lengkap (hilang)
5. Komponen seasonal dan komponen trend sangat kuat sehingga tidak akan mudah terdistorsi (,menyimpang)
6. Penerapan pada komputer lebih mudah dan perhitungan lebih cepat, bahkan untuk time series yang cukup lama

Definisi dari Loess itu sendiri adalah sebuah metode regresi non parametrik. Dimana regresi tersebut memiliki keunggulan, yaitu fleksibilitas yang tinggi karena data akan dengan sendirinya membentuk estimasi kurva yang tidak dipengaruhi oleh faktor subyektif (Silvestre et al., 2021)

Secara Matematis, model STL dapat ditulis

$$Y_t = S_t + T_t + E_t \quad t = 1 \text{ sampai dengan } t = n$$

Dimana

$Y_t$  = nilai deret waktu sebenarnya pada periode  $t$

$S_t$  = komponen musiman pada periode  $t$

$T_t$  = komponen trend-siklus pada periode  $t$

$E_t$  = komponen kesalahan pada periode  $t$

Langkah langkah dalam dekomposisi STL

a. Inner Loop

Setiap iterasi pada inner loop terdiri dari sebuah pemulusan musiman yang memperbarui komponen musiman, diikuti sebuah pemulusan trend yang memperbarui komponen trend

b. Outer Loop

Outer loop digunakan untuk menghitung komponen sisa (random) berdasarkan trend-siklus dan komponen musiman yang dihasilkan. Komponen sisa tersebut dilibatkan dalam estimasi deret keseluruhan melalui teknik kombinasi. Berdasarkan ekstraksi komponen sisa dari data pemisahan trend terekstrapolasi ( $T_{R \ T+1}$ ) dan deret pemisahan komponen musiman terekstrapolasi ( $S_{RT+1}$ ) Keduanya secara berurutan diperoleh dari menambahkan trend dengan sisa dan menambahkan musiman dengan sisa

## Peramalan dengan Model STL

Peramalan komponen trend, komponen musiman, dan komponen trend-sisa, dan komponen musiman-sisa dilakukan sesuai dengan komponen tersebut. Dengan mengombinasikan keempat komponen tersebut dapat diperoleh estimasi peramalan untuk deret waktu keseluruhan sebagai berikut

$$X_{t+1} = T T+1 + S T+1 + TR T+1 + SRT+1 / 2$$

## 2.2 Beban puncak

Beban puncak mengacu pada tingkat permintaan listrik maksimum yang dialami di wilayah tertentu selama jangka waktu tertentu. Beban puncak menunjukkan saat ketika permintaan energi berada pada titik tertingginya, biasanya pada waktu tertentu dalam sehari atau musim tertentu. Beban puncak merupakan faktor penting dalam perencanaan dan pengoperasian sistem distribusi listrik, yang memengaruhi alokasi sumber daya, perencanaan kapasitas, dan keandalan pasokan listrik. (Chumaidy,2019)

Waktu beban puncak mengacu pada periode saat penggunaan listrik mencapai level maksimumnya. Ini biasanya terjadi antara pukul 17.00 dan 23.00. Selama jam-jam ini, konsumsi listrik melonjak saat orang-orang pulang ke rumah dan melakukan aktivitas yang sangat bergantung pada perangkat listrik. Waktu beban puncak berakhir pada pukul 23.00, saat rumah tangga mematikan lampu dan peralatan mereka untuk bersiap tidur.(Dwipayana & Baraf,2020) PLN menggunakan dua istilah untuk membedakan periode pemakaian listrik pelanggannya, yaitu Waktu Beban Puncak (WBP) dan Waktu Beban Luar Puncak (LWBP). Istilah WBP digunakan karena periode ini merupakan waktu saat sebagian

besar pelanggan PLN menggunakan listrik secara serentak di rumah mereka. Biasanya, WBP berlangsung dari pukul 17.00 hingga pukul 22.00. Sebaliknya, Waktu Beban Luar Puncak mengacu pada periode pemakaian listrik yang terjadi di luar Waktu Beban Puncak. Data beban puncak di gardu induk sangat penting karena menunjukkan tingkat konsumsi listrik tertinggi selama rentang waktu tertentu, biasanya diukur dalam megawatt (MW). Analisis data ini sangat relevan bagi perusahaan penyedia listrik dan pengelola jaringan distribusi. Dalam konteks gardu induk, seperti gardu induk Palopo trafo I 20 MVA, data beban puncak dapat diperiksa untuk mengidentifikasi anomali yang menandakan lonjakan tidak biasa dalam konsumsi listrik. Oleh karena itu mendeteksi anomali beban puncak sangat penting karena memungkinkan identifikasi masalah potensial dalam sistem distribusi listrik, meningkatkan keandalan pasokan, dan mendukung pengambilan keputusan yang lebih tepat untuk perencanaan dan pengelolaan energi.

Data beban puncak trafo I 20 MVA yang akan digunakan untuk Identifikasi diperoleh dari PLN Palopo dan mencakup data konsumsi listrik periode 2019 hingga 2023. Data tersebut mencakup beberapa aspek penting, yaitu:

- a. Waktu beban puncak (WBP): Rincian lengkap mengenai nilai beban maksimum yang dicapai selama periode puncak, termasuk waktu pasti terjadinya beban puncak. Informasi ini penting untuk menilai sejauh mana utilisasi kapasitas transformator selama kondisi beban kritis.
- b. Luar waktu beban puncak (LWBP): Data ini menguraikan penggunaan daya selama periode non-puncak, termasuk rincian konsumsi daya minimum dan

rata-rata serta distribusi beban. Data ini digunakan untuk menilai efisiensi operasional dan distribusi energi.

- c. Tren Penggunaan Listrik Bulanan dan Tahunan: Ringkasan pola konsumsi energi berkala, yang mencakup total beban rata-rata, beban puncak, dan fluktuasi beban selama jangka waktu bulanan hingga tahunan.
- d. Fluktuasi Beban Harian: Pengamatan pada dinamika beban harian yang memberikan gambaran umum pola konsumsi berdasarkan jam operasional, menyoroti perbedaan penting antara periode puncak dan non-puncak.

### **2.3 Dekomposisi**

Komponen dekomposisi adalah bagian-bagian yang diperoleh dari memisahkan data asli ke dalam elemen-elemen utama dalam analisis deret waktu terdiri dari tiga bagian utama: trend, musiman (seasonal), dan residual (sis). Komponen trend menggambarkan arah perubahan jangka panjang dalam data, seperti kenaikan atau penurunan yang konsisten dari waktu ke waktu. Komponen musiman mencerminkan pola berulang secara periodik, yang biasanya dipengaruhi oleh faktor waktu seperti bulan, musim, atau hari tertentu. Sementara itu, komponen residual mewakili variasi acak atau noise dalam data yang tidak dapat dijelaskan oleh tren maupun pola musiman, sering kali mengindikasikan kejadian tidak terduga

Komponen-komponen ini dapat dijumlahkan kembali untuk merekonstruksi data asli. Ada dua jenis model yang digunakan dalam dekomposisi:

### 1. **Additive Model:**

$$Y(t)=T(t)+S(t)+R(t)$$

Digunakan ketika variasi musiman tidak bergantung pada tingkat tren (fluktuasi musiman tetap konstan).

### 2. **Multiplicative Model:**

$$Y(t)=T(t)\times S(t)\times R(t)$$

Digunakan ketika variasi musiman bergantung pada tingkat tren (fluktuasi musiman lebih besar pada data dengan nilai yang lebih tinggi)(Agnes Zahrani et al., 2021)

## 2.4 Gardu Induk

Gardu induk merupakan fasilitas penting dalam sistem distribusi tenaga listrik, yang berfungsi sebagai pusat pengaturan, pengendalian, dan penyaluran tenaga listrik dalam suatu wilayah atau area tertentu. Gardu induk, yang biasanya terletak di pusat jaringan distribusi tenaga listrik, berfungsi sebagai titik awal bagi sistem distribusi yang terhubung ke berbagai wilayah. Fungsi utamanya adalah untuk menaikkan atau menurunkan level tegangan. (Hidayat et al., 2022)

Gardu induk memainkan peran penting dalam sistem kelistrikan dengan menerima, memproses, dan mendistribusikan daya listrik dari generator ke jaringan distribusi. Fasilitas ini dilengkapi dengan komponen penting seperti transformator, sakelar, dan peralatan pelindung, yang memungkinkannya mengubah tegangan tinggi menjadi tegangan yang lebih rendah dan lebih aman untuk penggunaan konsumen. Ada berbagai jenis gardu induk, seperti gardu induk pembangkit, transmisi, dan distribusi, yang masing-masing memiliki tujuan khusus dalam

mengatur aliran listrik. Selain itu, gardu induk sangat penting untuk menggabungkan sumber energi terbarukan, menjaga stabilitas dan keandalan sistem kelistrikan, dan memastikan keselamatan melalui pemeliharaan rutin dan sistem perlindungan yang efisien.

## 2.5 Penelitian Sebelumnya

Tabel 2. 1 kajian Pustaka

| No | Peneliti                               | Judul Peneliti   | Hasil Penelitian   |
|----|--|--|--|
| 1  | Kurniawan, A., & Purnomo, H. D. (2024) | Sistem Deteksi Anomali Pada Transformator Menggunakan Dissolved Gas Analysis Dengan Metode K-Nearest Neighbour | Sistem deteksi anomali pada transformator berhasil dibuat dengan menggunakan lima metode DGA yang berbeda yaitu TDCG, Key Gass, Roger's Ratio, Doernenburg Ratio, dan Duval's Triangle dengan total 448 data yang didapatkan dari PT PLN Unit Pelaksana Transmisi (UPT) Salatiga. Memanfaatkan metode klasifikasi machine learning KNN memudahkan dalam menentukan tingkat akurasi dari suatu model sehingga dapat membandingkan metode mana yang memiliki akurasi tertinggi |



|   |   |  |  |
|---|---|--|--|
|   |   |  | dan baik digunakan untuk menentukan kondisi anomali pada suatu trafo.  |
| 2 | Kasun Bandaraa,<br>Rob J Hyndmanb,<br>Christoph<br>Bergmeir(2021) | MSTL: A Seasonal-Trend Decomposition Algorithm for Time Series with Multiple Seasonal Patterns | MSTL, sebuah algoritma dekomposisi deret waktu yang cepat dan mampu menangani deret waktu dengan siklus musiman ganda. Algoritma MSTL yang diusulkan merupakan perpanjangan dari algoritma dekomposisi STL, yang hanya dapat mengekstrak satu musim dari deret waktu. Hasil eksperimen pada data yang disimulasikan dan data nyata yang terpengaruh menunjukkan bahwa MSTL memberikan hasil yang kompetitif dengan biaya komputasi yang lebih rendah dibandingkan dengan algoritma |

|   |  |   |   |
|---|--|---|---|
|   |  |   | dekomposisi mutakhir lainnya, seperti STR, TBATS, dan PROPHET.  |
| 3 | Ahmad Haritsah(2015)   | Implementasi Model Stl Seasonal Trend Decomposition Based On Loess Dan Arima Untuk Prediksi Konsentrasi Kualitas Udara            | <p>1. Model STL dan ARIMA merupakan model terbaik yang digunakan untuk memprediksi CO dan SO<sub>2</sub></p> <p>2. Hilangnya data berpengaruh terhadap hasil prediksi karena pengaruh interpolasi pada data hilang tersebut.</p>  |
| 4 | Sónia Cristina, Clara Cordeiro, Samantha Lavender , Priscila Costa Goela, John Icely, and Alice Newton(2016) | MERIS Phytoplankton Time Series Products from the SW Iberian Peninsula (Sagres) Using Seasonal-Trend Decomposition Based on Loess | <p>Studi ini telah meneliti rangkaian waktu MERIS untuk produk reflektansi air, khususnya <math>\rho_w(\lambda)</math> dan Indeks Pigmen Alga 1 (API 1), di Sagres, yang terletak di pantai barat daya Iberia. Sifat optik wilayah ini telah dikarakterisasi secara menyeluruh melalui validasi in situ data MERIS yang dikumpulkan antara tahun 2008 dan 2012.</p> <p>Variasi rangkaian waktu MERIS telah dianalisis dan dipecah menjadi</p> |

|  |  |  |  |
|--|--|--|--|
|  |  |  | <p>komponen-komponen yang menandakan fluktuasi musiman (St), tren (Tt), dan ketidakteraturan (It) menggunakan dekomposisi Tren Musiman (STL) berbasis Loess. STL menawarkan beberapa manfaat, termasuk kapasitas untuk mendeteksi komponen musiman yang berkembang seiring waktu, respons terhadap tren nonlinier, dan ketahanan terhadap outlier. Selain itu, metode ini dapat digunakan dalam perangkat lunak R melalui fungsi <code>stl()</code>.</p> <p>Salah satu inovasi dalam penelitian ini adalah pengembangan fungsi <code>stl.fit()</code>, yang mempertahankan keunggulan STL sekaligus memungkinkan pemilihan model optimal secara otomatis dengan menyesuaikan nilai parameter pelunakan dalam</p> |
|--|--|--|--|

|   |   |   |  |
|---|---|---|--|
|   |   |   | upaya meminimalkan ukuran kesalahan.   |
| 5 | Qingsong Wen, Jingkun Gao, Xiaomin Song, Liang Sun, Huan Xu, Shenghuo Zhu(2019) | RobustSTL: A Robust Seasonal-Trend Decomposition Algorithm for Long Time Series | RobustSTL jauh lebih cepat dibandingkan dengan TBATS dan STR, karena algoritma ini dapat diformulasikan sebagai masalah optimisasi dengan regulasi norm-1 dan diselesaikan secara efisien. Meskipun STL standar tampak efisien secara komputasional, sensitivitasnya terhadap anomali dan ketidakmampuannya untuk menangkap perubahan tren serta pergeseran level membuatnya sulit digunakan pada data deret waktu kompleks dunia nyata yang sangat besar. men, juga diamati bahwa kecepatan komputasi |

|   |  |   |   |
|---|--|---|---|
| 6 | Zuokun Ouyang, Philippe Ravier and Meryem Jabloun,(2021) | STL Decomposition of Time Series Can Benefit Forecasting Done by Statistical Methods but Not by Machine Learning Ones | Temuan kami menunjukkan bahwa penggunaan dekomposisi STL sebagai teknik praproses dapat meningkatkan kinerja metode statistik secara signifikan, sejalan dengan studi Theodosiou [23] yang menggunakan data Kompetisi M1. Namun, pendekatan ini mungkin memiliki efek buruk pada metode pembelajaran mesin.   |
| 7 | Dicky Novanda Syaifullah, Rahmatina Hidayati(2024)       | PREDIKSI Kejadian Penyakit Tuberkulosis Paru Menggunakan Metode Peramalan Moving Averagedan Dekomposisi Time Series   | Temuan penelitian ini dirangkum sebagai berikut:<br>1. Metode peramalan dekomposisi perkalian menghasilkan MAPE terendah yaitu 15,37%, sehingga masuk dalam kategori baik jika dibandingkan dengan metode dekomposisi aditif dan rata-rata bergerak.<br>2. Terjadi peningkatan kasus tuberkulosis paru yang signifikan di RS X Kota Malang pada tahun 2022 dan 2023, dengan |

|   |   |   |   |
|---|---|---|---|
|   |   |   | <p>faktor risiko lebih tinggi pada laki-laki dibandingkan pada perempuan.</p> <p>3. Infeksi tuberkulosis paru menyerang semua kelompok umur, dengan insidensi tertinggi terjadi pada kelompok usia lanjut (usia 46-65 tahun) dan dewasa (usia 26-45 tahun).</p>   |
| 8 | MARQUARDTBe<br>rnadus Anggo Seno<br>Aji, Arliyanti<br>Nurdin,Pangestu<br>Widodo, Muh<br>Rizal Dwi(2020) | Deteksianomali Total<br>Electron<br>Contentsebelum<br>Gempa Bumi Palu<br>Menggunakan Jaringan<br>Syaraf Tiruan<br>Levenberg-Marquardt | <p>Metode Jaringan Syaraf Tiruan Lavenberg-Marquardt cukup baik dalam mendeteksi anomali yang terjadi pada data TEC. Anomali yang terjadi sebelum gempa bumi Palu, dideteksi H-3 dan H-0 sebelum gempa bumi serta H+1 Setelah gempa bumi. Pola anomali yang terjadi cenderung terlokalisasi di sekitar epicenter gempa. Pergerakan anomali memperlihatkan pergerakan ke kiri, sesuai dengan keadaan deformasi sesar Palu-Koro yang mempunyai pergerakan</p> |

|   |  |  |   |
|---|--|--|---|
|   |  |  | mendatar kekiri (Sinistral Slip Strike).  |
| 9 | Milka Wijayanti<br>Sunarto, Dendy<br>Kurniawan, Edy<br>Siswanto, Haris<br>Ihsanil Huda(2021) | Deteksi Anomali<br>Menggunakan<br>Extended Isolation<br>Forest (Eif) | Hasil pengujian menunjukkan bahwa Extended Isolation Model perlu disesuaikan. Tes kinerja deteksi anomali mengungkapkansedikit ketidaksempurnaan dalam deteksi struktur data jika dibandingkan dengan satu-satunya implementasi algoritma Python yang tersedia. Masalah ini dapat diperbaiki dengan sub-sampling yang lebih baik atau di percabangan iTree, di mana algoritme bisa menghindari titik perpecahan dengan leluhur kosong |

|    |  |   |  |
|----|--|---|--|
| 10 | Rifqi Karunia<br>Ibadirachman,<br>Yulison Herry<br>Chrisnanto, Puspita<br>Nurul<br>Sabrina(2024) | Optimasi Parameter<br>Dbscan Menggunakan<br>Metode Differential<br>Evolution untuk<br>Deteksi Anomali Pada<br>Data Transaksi Bank | Berdasarkan hasil<br>penelitian ini berhasil<br>mengoptimalkan parameter<br>DBSCAN, yaitu<br>MinPts dan Epsilon,<br>menggunakan metode<br>Differential<br>Evolution(DE). Hasilnya<br>menunjukkan bahwa<br>optimasi parameter ini<br>meningkatkan akurasi<br>deteksi anomali dalam data<br>transaksi bank. Iterasi<br>yang dilakukan<br>menunjukkan peningkatan<br>akurasi yang<br>stabil menggunakan<br>dengan DBI mencapai<br>0.19955, dengan hasil<br>terbaik mencapai akurasi<br>Z-Score 98.41% dan MSE<br>mencapai 0.671778 pada<br>penggunaan MinPts 4 dan<br>Eps 1,829 dapat<br>mendeteksi 17 anomali. |
|----|--|---|--|