

PENGOLAHAN DATA CURAH HUJAN MEMAKAI METODE DEKOMPOSISI BEAST DAN STL

Ginanjardwi Prasetyo^{1*}, Istiarto², Vempi Satriya Adi Hendrawan³

^{1,2,3}Departemen Teknik Sipil dan Lingkungan, Universitas Gadjah Mada, Sleman, Yogyakarta

*Email: ginanjardwiprasetyo@mail.ugm.ac.id

Abstrak

Curah hujan merupakan komponen penting dalam sistem hidrologi. Curah hujan dicatat dalam berbagai interval waktu. Data tersebut umumnya memiliki variasi yang tinggi. Hal tersebut mengakibatkan kecenderungan perubahan jangka panjang sulit diamati secara langsung. Penelitian ini bertujuan untuk mengidentifikasi kecenderungan perubahan curah hujan memakai metode dekomposisi runtut waktu. Data yang digunakan berupa data runtut waktu hujan harian di Stasiun Tawangmangu tahun 1980—2025 yang diubah menjadi data hujan bulanan. Metode yang digunakan adalah *Bayesian Estimator of Abrupt Change, Seasonality, and Trend* (BEAST) dan *Seasonal Trend Decomposition using Loess* (STL). Metode dekomposisi tersebut dapat memisahkan komponen *trend*, musiman, dan residu dari data runtut waktu. Hasil penelitian menunjukkan bahwa kedua metode mampu mendeteksi *trend* curah hujan. Metode BEAST memperlihatkan *trend* hujan bulanan meningkat dengan titik perubahan hujan bulanan pada 2016. Metode STL menghasilkan *trend* yang berfluktuasi, sehingga kecenderungan jangka panjang tidak terlihat jelas. Kedua metode menunjukkan pola musiman tahunan yang konsisten dengan residu acak. Berdasarkan hasil tersebut, metode BEAST lebih sesuai digunakan untuk mengidentifikasi *trend* curah hujan bulanan di Stasiun Tawangmangu tahun 1980—2025.

Kata kunci: BEAST, curah hujan, dekomposisi deret waktu, STL, *trend* curah hujan

Abstract

Rainfall is an important component of the hydrological system. It is recorded at various time intervals. The resulting data generally exhibit high variability. This condition makes long-term trends difficult to observe directly. This study aims to identify rainfall trends using time-series decomposition methods. The data used consist of daily rainfall observations at Tawangmangu Station from 1980 to 2025, which were aggregated into monthly rainfall data. The methods applied are the Bayesian Estimator of Abrupt Change, Seasonality, and Trend (BEAST) and Seasonal Trend Decomposition using Loess (STL). These decomposition methods separate the time series into trend, seasonal, and residual components. The results show that both methods are capable of detecting rainfall trends. The BEAST method reveals an increasing trend in monthly rainfall and identifies a change point in 2016. In contrast, the STL method produces a more fluctuating trend, making the long-term tendency less clearly defined. Both methods indicate a consistent annual seasonal pattern with random residual components. Based on these results, the BEAST method is more suitable for identifying rainfall trends at Tawangmangu Station during the period 1980 to 2025.

Keywords: BEAST, rainfall, time series decomposition, STL, rainfall trend

1. PENDAHULUAN

Curah hujan merupakan salah satu komponen utama dalam sistem hidrologi yang menentukan ketersediaan air di suatu wilayah. Pengukuran curah hujan dapat dilakukan secara langsung menggunakan alat ukur hujan dan dicatat secara kontinu dalam interval waktu tertentu. Data hasil pengukuran umumnya disimpan dalam bentuk curah hujan harian. Data harian tersebut memuat informasi mengenai dinamika kejadian hujan. Nilai curah hujan dapat berubah secara signifikan dari waktu ke waktu. Variasi harian yang besar sering menyebabkan kecenderungan perubahan jangka menengah dan jangka panjang tidak terlihat secara langsung. Oleh karena itu, pola temporal curah hujan harian sulit dipahami apabila data disajikan tanpa pengolahan lanjutan.

Pengolahan data hujan diperlukan agar pola perubahan data lebih mudah diidentifikasi. Data curah hujan sebagai data deret waktu dipengaruhi oleh beberapa komponen utama yaitu *trend*, musiman, dan residu. Ketiga komponen tersebut membentuk struktur temporal data curah hujan. Pemisahan komponen tersebut membantu dalam mengidentifikasi kecenderungan perubahan curah hujan.


Penelitian ini mengkaji karakteristik curah hujan salah satu stasiun di Daerah Aliran Sungai (DAS) Bengawan Solo. Kajian dilakukan menggunakan data curah hujan di Stasiun Tawangmangu. Stasiun ini berlokasi di Kecamatan Tawangmangu, Kabupaten Karanganyar, Provinsi Jawa Tengah (*Lon*: 111.1225, *Lat*:

-7.6665). Hasil penelitian ini diharapkan memberikan informasi mengenai kecenderungan perubahan curah hujan di lokasi studi.

2. METODOLOGI

2.1. Data Penelitian

Data curah hujan diperoleh dari laman Sistem Informasi Hidrologi dan Kualitas Air, Balai Besar Wilayah Sungai Bengawan Solo (<https://hidrologi.bbws-bsolo.net/>). Data curah hujan yang diperoleh merupakan data hujan harian tahun 1980 hingga tahun 2025. Kemudian, data hujan harian diubah menjadi data hujan bulanan. Data hujan bulanan diperoleh dari proses penjumlahan dari data hujan harian. Data tersebut digunakan sebagai *input* pengolahan data runtut waktu. Data hujan bulanan di Stasiun Tawangmangu tahun 1980—2025 ditunjukkan pada Gambar 1.



Gambar 1. Hujan bulanan di Stasiun Tawangmangu, DAS Bengawan Solo tahun 1980—2025.

2.2. Dekomposisi Data Curah Hujan

Metode dekomposisi deret waktu digunakan untuk memisahkan data curah hujan menjadi beberapa komponen. Komponen tersebut terdiri dari *trend*, musiman, dan residu. Menurut Kendall dan Ord (1990) *trend* adalah representasi deret waktu yang bersifat halus dan berubah secara berangsur-angsur (*smooth, relatively slowly changing*). Beberapa metode bahkan memiliki kemampuan mendeteksi titik perubahan dalam komponen *trend*. Titik perubahan *trend* adalah waktu terjadinya perubahan pola kecenderungan data secara signifikan, misalnya dari kondisi stabil menjadi meningkat atau sebaliknya. Musiman adalah perubahan siklus suhu dan atau curah hujan [Kwiecien dkk., 2022] yang memiliki efek keteraturan [Kendall dan Ord, 1990]. Pola musiman menunjukkan nilai cenderung tinggi atau rendah pada waktu tertentu [Helsel dan Hirsch, 2002]. Residu adalah sisa data setelah komponen *trend* dan musiman dihilangkan yang dapat bersifat acak atau memiliki pola [Chatfield, 1996]. Proses dekomposisi tidak menghilangkan makna fisik data karena metode ini hanya menguraikan data curah hujan menjadi komponen yang sederhana. Penelitian ini memasukkan data curah hujan sebagai *input*, kemudian menjalankan program dekomposisi, dan menghasilkan *output* berupa komponen *trend*, musiman, dan residu.

2.2.1. Metode *Bayesian Estimator of Abrupt Change, Seasonality, and Trend* (BEAST)

Metode BEAST dihitung memakai program Rbeast. Program tersebut dikembangkan oleh [Zhao dkk., 2019] menggunakan bahasa pemrograman C/C++ yang juga berjalan pada bahasa program R dan Python. Rbeast dapat dijalankan dengan *software* Matlab, Octave [Hu dkk., 2025], Spyder, Rstudio, dan *software* lain yang mendukung. Kode program Rbeast dapat diakses melalui <https://github.com/zhaokg/Rbeast>. Persamaan dekomposisi metode BEAST dinyatakan sebagai berikut.

$$Y_t = T_t + S_t + R_t \quad (1)$$

Y_t = curah hujan aktual pada waktu ke- t (mm),

T_t = komponen *trend*,

S_t adalah komponen musiman (mm), dan

R_t = komponen residu (mm).

Dalam menjalankan perangkat lunak dekomposisi perlu ditentukan parameter yang dipakai. Data runtut waktu yang digunakan menjadi dasar penentuan nilai parameter dekomposisi. Data masukan dalam penelitian

ini berupa data hujan harian yang dikonversi menjadi data hujan bulanan di dalam perangkat lunak. Perangkat lunak Rbeast memiliki nilai $deltat$ yang ditentukan berdasarkan interval nilai data yaitu data bulanan yang dinyatakan dalam satuan tahun ($1/12$ tahun). Nilai $freq$ ditentukan berdasarkan jumlah data dalam satu siklus musiman tahunan yaitu 12 untuk data bulanan. Nilai parameter $season$ ditetapkan sebagai *harmonic*. Nilai tersebut berarti data runtut waktu memiliki komponen musiman. Penjelasan lebih lanjut terkait metode BEAST disajikan dalam [The Comprehensive R Archive Network, 2025; Zhao dkk., 2019]. Parameter yang digunakan dalam proses dekomposisi metode BEAST dapat dilihat pada Tabel 1.

Tabel 1. Parameter metode dekomposisi BEAST

Parameter	Nilai	Keterangan
$deltat$	$1/12$	Interval waktu antar nilai data.
$freq$	12	Jumlah data dalam satu siklus.
$season$	<i>harmonic</i>	Jenis atau keberadaan komponen musiman.

2.2.2. Metode Seasonal Trend Decomposition using Loess (STL)

Metode STL dihitung memakai program STL Decomposition. Program tersebut dikembangkan oleh Afedullah (2025) menggunakan bahasa pemrograman Python. Program memanfaatkan metode STL dari pustaka statsmodels—modul Python yang menyediakan fungsi untuk mengestimasi berbagai model statistik [Statsmodels, 2025]. Kode program dapat diakses melalui <https://medium.com/@afedullah/stl-decomposition-of-chirps-precipitation-data-using-google-earth-engine-python-0b18664d810b>. Persamaan dekomposisi metode STL dinyatakan sebagai berikut.

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

Tiap perangkat lunak memungkinkan parameter didefinisikan berbeda. Dalam perangkat lunak STL Decomposition, nilai parameter $seasonal$ ditentukan berdasarkan periode musiman tahunan dalam data bulanan. Persyaratan nilai $seasonal$ harus bilangan ganjil. Nilai $seasonal = 12$, namun karena nilai harus ganjil jadi dipakai nilai $seasonal = 13$. Nilai $seasonal$ menunjukkan siklus musiman. Nilai $trend$ diperoleh dengan rumus yang disediakan [Cleveland dkk., 1990] sebagai berikut.

$$n_{(t)} \geq \frac{1.5 n_{(p)}}{1 - 1.5 n_{(s)}^{-1}} \quad (3)$$

$n_{(t)}$ = $trend$ = parameter *trend smoothing*,

$n_{(p)}$ = jumlah data tiap siklus musiman, dan

$n_{(s)}$ = $seasonal$ = parameter *seasonal smoothing*.

Jika $n_{(s)} \geq 7$ maka berlaku $n_{(t)}$ antara $1.5 n_{(p)}$ hingga $2 n_{(p)}$. Nilai $trend$ ditentukan lebih besar daripada $seasonal$ dan harus bilangan ganjil. Penjelasan lebih lanjut mengenai metode STL disajikan dalam Cleveland dkk. (1990) dan Statsmodels (2025). Parameter yang digunakan dalam proses dekomposisi metode STL ditampilkan pada Tabel 2.


Tabel 2. Parameter metode dekomposisi STL

Parameter	Nilai	Keterangan
$seasonal$	13	Parameter <i>seasonal smoothing</i> (harus ganjil, $seasonal \geq 7$).
$trend$	21	Parameter <i>trend smoothing</i> (harus ganjil; $trend > seasonal$).

3. HASIL DAN PEMBAHASAN

3.1. Karakteristik Hujan Bulanan di Stasiun Tawangmangu (1980—2025)

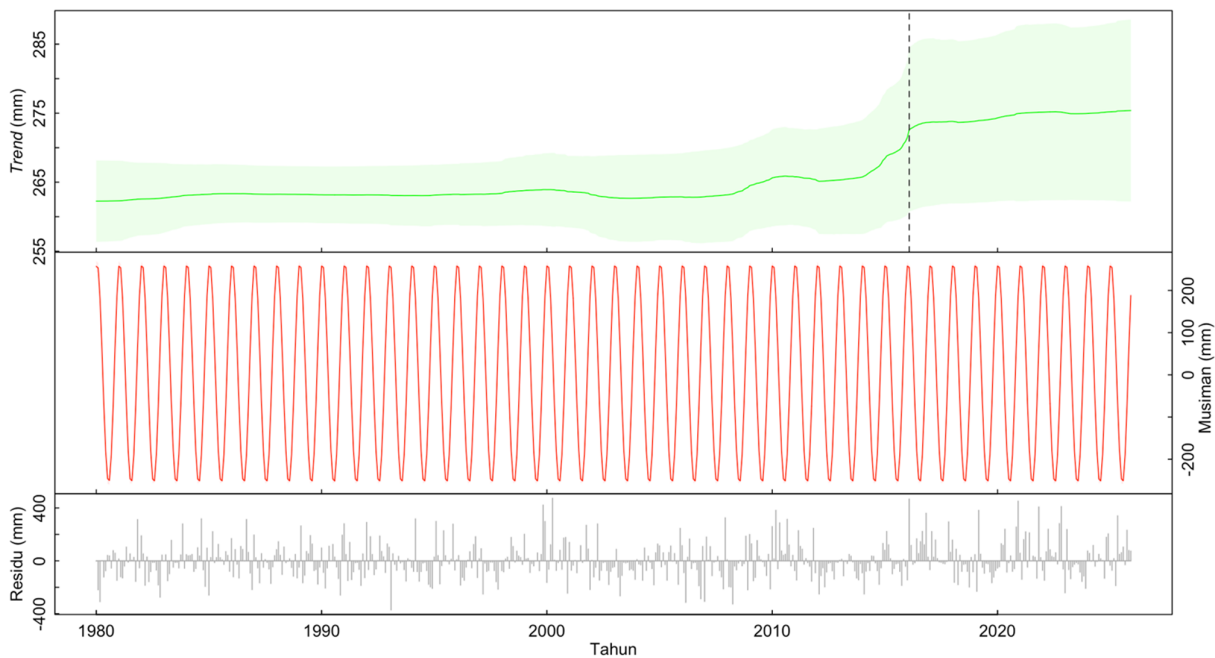
Jumlah data yang dipakai adalah 552 hujan bulanan. Nilai rerata curah hujan bulanan selama 46 tahun (1980—2025) sebesar 266 mm. Nilai curah hujan bulanan maksimum sebesar 992 mm yang terjadi pada tahun 2016. Nilai curah hujan bulanan minimum sebesar 0 mm yang menunjukkan kondisi tanpa hujan. Data curah hujan bulanan tidak ditemukan adanya *outlier*. Nilai batas bawah dan atas *outlier* berturut-turut -547 mm dan 1044 mm. Karakteristik hujan bulanan di Stasiun Tawangmangu tahun 1980—2025 ditunjukkan pada Gambar 2.



Gambar 2. Karakteristik Hujan bulanan di Stasiun Tawangmangu, DAS Bengawan Solo tahun 1980—2025.

3.2. Hasil Dekomposisi Data Hujan Bulanan di Stasiun Tawangmangu Metode BEAST


Hasil dekomposisi data hujan bulanan memakai program Rbeast menampilkan komponen *trend*, musiman, dan residu. Kurva hijau pada metode BEAST merupakan pola *trend*, sedangkan area berwarna hijau merupakan rentang ketidakpastian (*credible interval*—rentang nilai yang dipercaya mengandung nilai sebenarnya). Kurva *trend* menunjukkan kecenderungan hujan bulanan yang meningkat. Nilai *trend* berkisar antara 260 hingga 270 mm selama tahun 1980—2025. Lebar rentang ketidakpastian hujan bulanan bervariasi, rentang ini cenderung sempit pada tahun 1980 kemudian melebar hingga tahun 2025. Selain itu, ada satu titik perubahan yang terdeteksi oleh metode BEAST yaitu pada tahun 2016. Pola musiman membentuk siklus tahunan dengan amplitudo berkisar -200 mm hingga 200 mm. Nilai residu berkisar antara -400 mm hingga 400 mm. Hasil dekomposisi data hujan bulanan di Stasiun Tawangmangu periode 1980—2025 ke komponen *trend*, musiman, dan residu memakai metode BEAST ditunjukkan pada Gambar 3.



Gambar 3. Dekomposisi data hujan bulanan di Stasiun Tawangmangu periode 1980—2025 ke komponen *trend*, musiman, dan residu memakai metode BEAST.

3.3. Hasil Dekomposisi Data Hujan Bulanan di Stasiun Tawangmangu Metode STL (1980—2025)

Hasil dekomposisi curah hujan memakai program STL Decomposition menampilkan komponen *trend*, musiman, dan residu. Komponen *trend* memperlihatkan nilai berkisar antara 150 mm hingga 400 mm. Kurva *trend* menunjukkan beberapa fase peningkatan dan penurunan hujan bulanan sepanjang deret waktu. Amplitudo musiman berkisar antara -200 mm hingga 250 mm. Nilai residu berkisar antara -200 mm hingga 400 mm. Hasil dekomposisi data hujan bulanan di Stasiun Tawangmangu periode 1980—2025 ke komponen *trend*, musiman, dan residu memakai metode STL ditunjukkan pada Gambar 4.



Gambar 4. Dekomposisi data hujan bulanan di Stasiun Tawangmangu periode 1980—2025 ke komponen *trend*, musiman, dan residu memakai metode STL.

3.4. Perbandingan Komponen Dekomposisi Data Hujan Bulanan di Stasiun Tawangmangu Metode BEAST dan STL (1980—2025)

3.4.1. Komponen *Trend*

Metode BEAST menunjukkan *trend* hujan bulanan yang jelas. Namun, semakin lebar *credible interval* maka semakin tidak pasti suatu *trend*, sedangkan semakin sempit *credible interval* maka semakin meyakinkan *trend* tersebut. Penelitian [Li dkk., 2022; Wang dkk., 2024; Xiang dkk., 2023] mengungkapkan metode BEAST dapat mendeteksi titik perubahan *trend* mendadak data runtut waktu. Hal ini sejalan dengan temuan penelitian ini, bahwa ada satu titik perubahan *trend* curah hujan bulanan di Stasiun Tawangmangu pada tahun 2016. Titik ini menunjukkan adanya perubahan karakteristik curah hujan bulanan di Stasiun Tawangmangu tahun 1980—2025. Kemampuan metode BEAST dalam mendeteksi titik perubahan *trend* berasal dari pendekatan Bayesian yang secara eksplisit memodelkan perubahan struktur data runtut waktu. Sedangkan, metode STL tidak dirancang untuk mendeteksi titik perubahan *trend* karena hanya menggunakan pendekatan *smoothing* untuk memisahkan komponen—*trend*, musiman, dan residu—dalam data. Metode STL memperlihatkan bentuk kurva *trend* saja. Kurva *trend* metode STL menampilkan hujan bulanan yang dominan berfluktuasi (naik-turun). Sehingga, arah *trend* hujan bulanan jangka panjang tidak terlihat jelas. Hal ini dikarenakan nilai parameter *trend* yang dipakai. Apabila nilai *trend* metode STL kecil maka pola garis *trend* hujan bulanan semakin kasar dan berubah cepat.

3.4.2. Komponen Musiman

Metode BEAST menghasilkan musiman hujan bulanan dengan pola yang halus, ukuran bukit-lembah yang konsisten dan pola berulang setiap tahun/teratur. Metode STL memperlihatkan pola musiman yang cenderung lebih kasar dibandingkan metode BEAST. Pola musiman metode STL teratur namun ukuran bukit-lembah bervariasi. Secara umum, metode BEAST dan STL sama-sama menunjukkan keteraturan musim. Setiap awal satu tahun terjadi bukit dan setiap pertengahan satu tahun terjadi lembah. Hujan bulanan yang tinggi dominan terjadi di awal tahun dan hujan bulanan yang rendah dominan terjadi di pertengahan tahun. Hal ini sesuai penelitian [Sekaranom dkk., 2018] bahwa puncak musim hujan di Jawa Tengah terjadi pada bulan Desember—Februari dan puncak musim kemarau terjadi pada bulan Juni—Agustus.

3.4.3. Komponen Residu

Komponen residu hujan bulanan metode BEAST dan STL menunjukkan pola yang berfluktuasi acak. Fluktuasi acak ini merupakan salah satu efek dari kejadian ekstrem seperti bencana alam [Das dan Barman, 2025]. Nilai residu merupakan selisih antara curah hujan aktual dengan nilai komponen *trend* dan musiman.

Residu bernilai positif berarti curah hujan aktual lebih tinggi dari jumlah nilai *trend* dan musiman, sebaliknya apabila residu bernilai negatif artinya curah hujan aktual lebih rendah dari jumlah nilai *trend* dan musiman. Metode BEAST dan STL belum dapat memperlihatkan anomali data runtut waktu secara kuantitatif. Kedua metode ini tidak menyediakan kriteria batas (*threshold*) atau indikator statistik yang jelas. Penelitian lanjutan mengenai deteksi anomali komponen residu seperti *density-based spatial clustering of applications with noise* (DBSCAN) [Ester dkk., 1996], *extended isolation forest* (EIF) [Hariri dkk., 2021], dan metode lain mungkin diperlukan. Penerapan metode DBSCAN dan EIF berturut-turut pernah dilakukan Song dkk. (2025) dan Fichtner dkk. (2023).

3.5. Hubungan Karakteristik Curah Hujan Bulanan di Stasiun Tawangmangu (1980—2025) dengan Metode BEAST dan STL

Data curah hujan bulanan di Stasiun Tawangmangu tidak terdapat adanya nilai hilang (*missing values*) maupun pencilan (*outlier*). Dalam hal ini, proses dekomposisi metode BEAST dan STL dilakukan dengan data lengkap tanpa simulasi nilai hilang dan pencilan. Meskipun demikian, metode BEAST dan STL dirancang untuk menyelesaikan masalah tersebut. Penelitian [Hu dkk., 2021] menunjukkan bahwa metode BEAST dapat menangani 56,1% nilai data runtut waktu yang hilang dari 443 nilai data. Metode STL memiliki keterbatasan menyelesaikan persoalan nilai hilang terutama ketika nilai hilang mempunyai gap/celah yang besar [Kwok dkk., 2023]. Maka diperlukan *imputations* (pengisian nilai yang hilang) di luar metode STL. Perangkat lunak seperti *statsmodels* memungkinkan penggunaan fungsi *forward fill* (*ffill*) untuk *imputations* [Statsmodels, 2025].

4. KESIMPULAN

Curah hujan bulanan di Stasiun Tawangmangu (1980—2025) menunjukkan adanya kecenderungan perubahan (*trend*). Metode BEAST dan STL sama-sama mampu mendeteksi *trend* data runtut waktu. Metode BEAST menghasilkan *trend* jangka panjang yang jelas, sedangkan metode STL menghasilkan *trend* yang berfluktuasi (tidak jelas). Perbedaan tersebut dipengaruhi oleh nilai parameter yang digunakan. Penentuan parameter berpotensi memengaruhi hasil dekomposisi sehingga perlu diperhatikan dalam penggunaan metode. Selain itu, metode BEAST dapat mendeteksi titik perubahan *trend* curah hujan bulanan, sedangkan metode STL tidak memiliki kemampuan tersebut. Berdasarkan penelitian yang dilakukan, metode BEAST lebih cocok dibanding metode STL untuk mengidentifikasi *trend* hujan bulanan di Stasiun Tawangmangu (1980—2025).

DAFTAR PUSTAKA

- Afedullah, A. (2025). *STL Decomposition of CHIRPS Precipitation Data Using Google Earth Engine dan Python*. Medium. <https://medium.com/@afedullah/stl-decomposition-of-chirps-precipitation-data-using-google-earth-engine-python-0b18664d810b>
- Chatfield, C. (1996). *The Analysis of Time Series* (5th Edition). Chapman dan Hall/CRC. https://is.muni.cz/el/econ/podzim2009/MPM_AEMM/um/NotSortedYet/Chatfield_The_Analysis_of_Time_Series_An_Introduction_5ed.pdf
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*, 6(1), 3–73.
- Das, P., & Barman, S. (2025). Perspective Chapter: An Overview of Time Series Decomposition and Its Applications. In *Applied and Theoretical Econometrics and Financial Crises*. <https://doi.org/10.5772/intechopen.1009268>
- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X. (1996). A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. *KDD-96 Proceedings*. www.aaai.org
- Fichtner, F., Mandery, N., Wieland, M., Groth, S., Martinis, S., & Riedlinger, T. (2023). Time-series analysis of Sentinel-1/2 data for flood detection using a discrete global grid system and seasonal decomposition. *International Journal of Applied Earth Observation and Geoinformation*, 119. <https://doi.org/10.1016/j.jag.2023.103329>
- Hariri, S., Kind, M. C., & Brunner, R. J. (2021). Extended Isolation Forest. *IEEE Transactions on Knowledge and Data Engineering*, 33(4), 1479–1489. <https://doi.org/10.1109/TKDE.2019.2947676>
- Helsel, D. R., & Hirsch, R. M. (2002). Statistical Methods in Water Resources. In *Hydrologic Analysis and Interpretation* (A3). US Geological Survey. <http://water.usgs.gov/pubs/twri/twri4a3/>

- Hu, T., Li, Y., Zhang, X., & Zhao, K. (2025). Rbeast: Bayesian Change-Point Detection and Time Series Decomposition. In *CRAN: Contributed Packages* (1.0.2). The Comprehensive R Archive Network. <https://doi.org/10.32614/CRAN.package.Rbeast>
- Hu, T., Myers Toman, E., Chen, G., Shao, G., Zhou, Y., Li, Y., Zhao, K., & Feng, Y. (2021). Mapping fine-scale human disturbances in a working landscape with Landsat time series on Google Earth Engine. *ISPRS Journal of Photogrammetry and Remote Sensing*, 176, 250–261. <https://doi.org/10.1016/j.isprsjprs.2021.04.008>
- Kendall, M. G., & Ord, K. J. (1990). *Time Series* (3rd Edition). Oxford University Press. https://archive.org/details/timeseries0003kend_y1p7
- Kwiecien, O., Braun, T., Brunello, C. F., Faulkner, P., Hausmann, N., Helle, G., Hoggarth, J. A., Ionita, M., Jazwa, C. S., Kelmelis, S., Marwan, N., Nava-Fernandez, C., Nehme, C., Opel, T., Oster, J. L., Perşoiu, A., Petrie, C., Prufer, K., Saarni, S. M., ... Breitenbach, S. F. M. (2022). What we talk about when we talk about seasonality – A transdisciplinary review. *Earth-Science Reviews*, 225. <https://doi.org/10.1016/j.earscirev.2021.103843>
- Kwok, C. F., Qian, G., & Kuleshov, Y. (2023). Analyzing Error Bounds for Seasonal-Trend Decomposition of Antarctica Temperature Time Series Involving Missing Data. *Atmosphere*, 14(2). <https://doi.org/10.3390/atmos14020193>
- Li, J., Li, Z. L., Wu, H., & You, N. (2022). Trend, seasonality, and abrupt change detection method for land surface temperature time-series analysis: Evaluation and improvement. *Remote Sensing of Environment*, 280. <https://doi.org/10.1016/j.rse.2022.113222>
- Sekaranom, A. B., Nurjani, E., Hadi, M. P., & Marfai, M. A. (2018). Comparison of TRMM Precipitation Satellite Data over Central Java Region - Indonesia. *Quaestiones Geographicae*, 37(3), 97–114. <https://doi.org/10.2478/quageo-2018-0028>
- Song, C., Cui, J., Cui, Y., Zhang, S., Wu, C., Qin, X., Wu, Q., Chi, S., Yang, M., Liu, J., Chen, R., & Zhang, H. (2025). Integrated STL-DBSCAN algorithm for online hydrological and water quality monitoring data cleaning. *Environmental Modelling and Software*, 183. <https://doi.org/10.1016/j.envsoft.2024.106262>
- Statsmodels. (2025). *statsmodels* (0.14.6). Github. <https://github.com/statsmodels/statsmodels>
- The Comprehensive R Archive Network. (2025, December 19). *Help for Package Rbeast*. <https://cran.r-project.org/web/packages/Rbeast/refman/Rbeast.html>
- Wang, Y., Zhang, X., Zhao, K., & Singh, D. (2024). Streamflow in the United States: Characteristics, trends, regime shifts, and extremes. *Scientific Data*, 11(1). <https://doi.org/10.1038/s41597-024-03618-0>
- Xiang, J., Cui, T., Li, X., Zhang, Q., Mu, B., Liu, R., & Zhao, W. (2023). Evaluating the effectiveness of coastal environmental management policies in China: The case of Bohai Sea. *Journal of Environmental Management*, 338. <https://doi.org/10.1016/j.jenvman.2023.117812>
- Zhao, K., Wulder, M. A., Hu, T., Bright, R., Wu, Q., Qin, H., Li, Y., Toman, E., Mallick, B., Zhang, X., & Brown, M. (2019). Detecting change-point, trend, and seasonality in satellite time series data to track abrupt changes and nonlinear dynamics: A Bayesian ensemble algorithm. *Remote Sensing of Environment*, 232. <https://doi.org/10.1016/j.rse.2019.04.034>