



The Effect of Environmental Factors on the Distribution of Dange Fever Cases in South Jakarta Using Geographically and Temporally Weighted Regression (GTWR) Approach

Pengaruh Faktor Lingkungan Terhadap Distribusi Kasus DBD di Jakarta Selatan Menggunakan Pendekatan *Geographically and Temporally Weighted Regression* (GTWR)

Savvy Prissy Amellia Carissa^{1*}, Nova Putri Dwi Sugiarti²,
Trimono³, Mohammad Idhom⁴

^{1,2,3,4}Program Studi Sains Data, Fakultas Ilmu Komputer,
Universitas Pembangunan Nasional “Veteran”, Jawa Timur, Indonesia

E-Mail: ¹22083010009@student.upnjatim.ac.id, ²22083010088@student.upnjatim.ac.id,
³trimono.stat@upnjatim.ac.id, ⁴idhom@upnjatim.ac.id

Received Jun 17th 2025; Revised Sep 19th 2025; Accepted Sep 25th 2025; Available Online Oct 30th 2025

Corresponding Author: Savvy Prissy Amellia Carissa

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Dengue Hemorrhagic Fever (DHF) is an endemic disease influenced by numerous environmental factors, exhibiting a complex spatial and temporal distribution pattern. Using the Geographically and Temporally Weighted Regression (GTWR) approach, this study aims to analyze the distribution of DHF cases in the South Jakarta area. Maximum and minimum temperatures have a consistent positive impact on the increase in dengue cases, according to the study's results. The performance of the GTWR model is indicated by an R-squared value of 0.5697 and an AIC of 556.766. The risk map visualization identifies areas such as Jagakarsa, Cilandak, and Mampang Prapatan as high-risk areas. Seasonal patterns show an increase in cases from early to mid-year and a decrease during the dry season.

Keyword: *Dengue Hemorrhagic Fever, Environmental Factors, GTWR, South Jakarta*

Abstrak

Demam Berdarah *Dengue* (DBD) adalah penyakit endemis yang dipengaruhi oleh banyak faktor lingkungan dan memiliki pola penyebaran yang kompleks secara spasial dan temporal. Dengan menggunakan pendekatan *Geographically and Temporally Weighted Regression* (GTWR), penelitian ini bertujuan untuk menganalisis distribusi kasus DBD di wilayah Jakarta Selatan. Suhu maksimum dan suhu minimum memiliki dampak positif yang konsisten terhadap peningkatan kasus DBD, menurut hasil penelitian. Kinerja model GTWR ditunjukkan dengan nilai *R-squared* 0,5697 dan AIC 556,766. Visualisasi peta risiko mengidentifikasi wilayah seperti Jagakarsa, Cilandak, dan Mampang Prapatan sebagai daerah dengan risiko tinggi, dan pola musiman memperlihatkan peningkatan kasus pada awal hingga pertengahan tahun serta penurunan pada musim kemarau.

Kata Kunci: Demam Berdarah *Dengue*, Faktor Lingkungan, GTWR, Jakarta Selatan

1. PENDAHULUAN

Demam Berdarah *Dangue* (DBD) masih menjadi salah satu masalah kesehatan masyarakat utama di wilayah tropis termasuk wilayah Jakarta Selatan. Kasus DBD di Jakarta Selatan masih menjadi masalah serius. Berdasarkan data Suku Dinas Kesehatan Jakarta Selatan, tercatat 428 kasus DBD dari Januari hingga pertengahan April 2025. Jumlah kasus tertinggi tercatat pada bulan Januari sebanyak 169 kasus, kemudian menurun menjadi 141 kasus pada Februari, 110 kasus pada Maret, dan hanya 8 kasus pada April. Angka tersebut jauh lebih rendah dibandingkan dengan periode yang sama tahun 2024 yang mencatat mencapai 1.302 kasus dari Januari hingga pertengahan April. Dari sisi distribusi wilayah, Kecamatan Jagakarsa mencatat jumlah kasus tertinggi yaitu 71 kasus, sementara Kecamatan Tebet memiliki jumlah kasus paling

sedikit yaitu 14 kasus [1]. Meskipun tren pada kasus menurun, potensi meningkatnya kasus DBD masih dapat terjadi terutama pada puncak musim hujan yang berlangsung antara bulan April sampai Mei [2].

Upaya pencegahan dan pengendalian DBD telah dilakukan melalui berbagai program seperti Pemberantasan Sarang Nyamuk (PSN) 3M Plus, *fogging*, peran kader Jumantik, dan edukasi kesehatan masyarakat. Namun, efektivitas dari upaya program tersebut belum konsisten dalam menekan jumlah kasus DBD secara berkelanjutan. Hal tersebut kemungkinan besar disebabkan oleh pendekatan pengendalian yang masih bersifat umum dan belum mempertimbangkan perbedaan karakteristik wilayah serta dinamika kondisi lingkungan dari waktu ke waktu. Namun demikian, penyebaran DBD merupakan fenomena yang kompleks yang melibatkan variasi spasial antarwilayah dan variasi temporal antar periode. Faktor lingkungan seperti curah hujan, suhu, kelembaban, dan kepadatan penduduk memiliki peran penting dalam menentukan tingkat risiko penyebaran DBD [3]. Wilayah dengan kepadatan penduduk yang tinggi, memiliki kerentanan yang lebih besar karena tingginya intensitas interaksi antara manusia dengan nyamuk.

Berdasarkan hal tersebut, diperlukan suatu pendekatan analisis yang mampu menangkap variasi lokal dan dinamika waktu secara bersamaan untuk memahami dinamika penyebaran DBD secara komprehensif [4]. Salah satu metode yang relevan untuk digunakan adalah *Geographically and Temporally Weighted Regression* (GTWR). Pendekatan ini memungkinkan analisis hubungan antara faktor lingkungan dan kasus DBD dengan mempertimbangkan keunikan wilayah serta perubahan kondisi dari waktu ke waktu [5]. GTWR juga memberikan keunggulan dibandingkan dengan metode regresi konvensional yang cenderung mengabaikan heterogenitas spasial – temporal, sehingga hasil dari analisis lebih presisi dan adaptif [6].

Dengan demikian, tujuan dari penelitian yang menganalisis pengaruh faktor lingkungan dan sosial terhadap penyebaran DBD di Jakarta Selatan berdasarkan variasi spasial dan temporal menjadi penting untuk dilakukan, sehingga penelitian ini berfokus pada pengaruh faktor lingkungan terhadap distribusi kasus DBD di Jakarta Selatan yang menggunakan pendekatan GTWR. Selain itu, penelitian ini juga bertujuan untuk menggambarkan pola distribusi kasus DBD dan menyajikan hasil analisis dalam bentuk peta risiko yang dapat dimanfaatkan sebagai dasar penyusunan strategi pengendalian penyakit yang lebih tepat sasaran. Oleh karena itu, penelitian ini diharapkan mampu memberikan kontribusi dalam pengembangan kebijakan kesehatan berbasis bukti (*evidence-based policy*), sehingga strategi pengendalian DBD dapat disusun tidak secara seragam melainkan disesuaikan dengan karakteristik lokal dan dinamika temporal masing – masing wilayah.

Beberapa penelitian terkait salah satunya berjudul “*Analisis Spasial – Temporal Incidence Rate Demam Berdarah Dengue di Bali dengan Pendekatan Distribusi Gamma*” yang ditulis oleh Nur Sofiyulloh, membahas terkait penyebaran penyakit DBD di Provinsi Bali pada tahun 2017 melalui analisis spasial dan temporal. Penelitian ini menggunakan metode regresi Gamma yaitu *Geographically Weighted Gamma Regression* (GWGR) dan GTWR. Hasil penelitian ini menunjukkan bahwa faktor-faktor yang mempengaruhi terhadap *incidence rate* di Bali, antara lain curah hujan, suhu, dan kelembaban udara. Pada pemodelan GWGR menghasilkan 5 kelompok kabupaten/kota di Provinsi Bali yang memiliki kesamaan variabel signifikan terhadap *incidence rate*, sedangkan pemodelan GTWR menghasilkan mayoritas *incidence rate* demam berdarah di daerah kabupaten/kota pada tahun 2014 hingga 2016 dipengaruhi oleh faktor rata-rata suhu dan setiap daerah memiliki minimal satu faktor iklim yang berpengaruh pada tiap bulannya. Dari kedua model setelah dilakukan analisis berdasarkan nilai AICc, bahwa model GTWR merupakan pemodelan terbaik dibandingkan dengan model GWGR.

Penelitian selanjutnya yang dilakukan oleh Eggy yang berjudul “*Analisis Faktor Spasial Terhadap Kejadian Demam Berdarah Dengue Menggunakan Pendekatan Geographically Weighted Regression (GWR) di Kota Pekanbaru, Provinsi Riau*” [7]. Penelitian ini membahas tentang analisis faktor spasial yang memengaruhi kejadian penyakit DBD di Kota Pekanbaru, Provinsi Riau. Tujuan utama dari penelitian ini adalah untuk mengidentifikasi faktor-faktor lingkungan dan sosial yang berkontribusi terhadap penyebaran DBD dengan pendekatan spasial. Peneliti menggunakan metode GWR untuk menganalisis hubungan antara kejadian DBD dengan variabel-variabel seperti kepadatan penduduk, fasilitas kesehatan, kepadatan bangunan, proporsi penduduk usia < 15 tahun, ketinggian, dan curah hujan. Hasil penelitian menunjukkan bahwa variabel fasilitas kesehatan, usia < 15 tahun, dan ketinggian memiliki pengaruh signifikan terhadap kasus DBD. Nilai *Local R-Square* tertinggi mencapai 65,03%, menandakan bahwa model GWR mampu menjelaskan sebagian besar variasi spasial kejadian DBD. Variabel fasilitas kesehatan menjadi faktor paling dominan, dengan koefisien tertinggi sebesar 4,4375.

Penelitian lainnya berjudul “*Pemetaan Kejadian Balita Stunting Melalui Integrasi Citra Satelit Multisumber dan Official Statistics di Provinsi Nusa Tenggara Timur Menggunakan Machine Learning*” yang ditulis oleh SW Prayoga [8], membahas terkait kejadian bayi *stunting* di Provinsi Nusa Tenggara Timur. Penelitian ini melakukan pemetaan kejadian *stunting* dengan mengintegrasikan citra satelit multisumber dan *official statistic* menggunakan algoritma *machine learning*. Metode yang digunakan dalam penelitian ini adalah *non-hierarchical clustering* berupa *K-Means*, *K-Medoids*, dan *Fuzzy C-Means*. Berdasarkan hasil validasi internal hasil penelitian ini menunjukkan *K-Means* dinilai sebagai metode *clustering* terbaik dalam

penelitian ini. Adapun hasil pemetaan menunjukkan bahwa wilayah yang tergolong ke dalam kluster dua merupakan daerah yang masih sangat rentan terhadap permasalahan *stunting*.

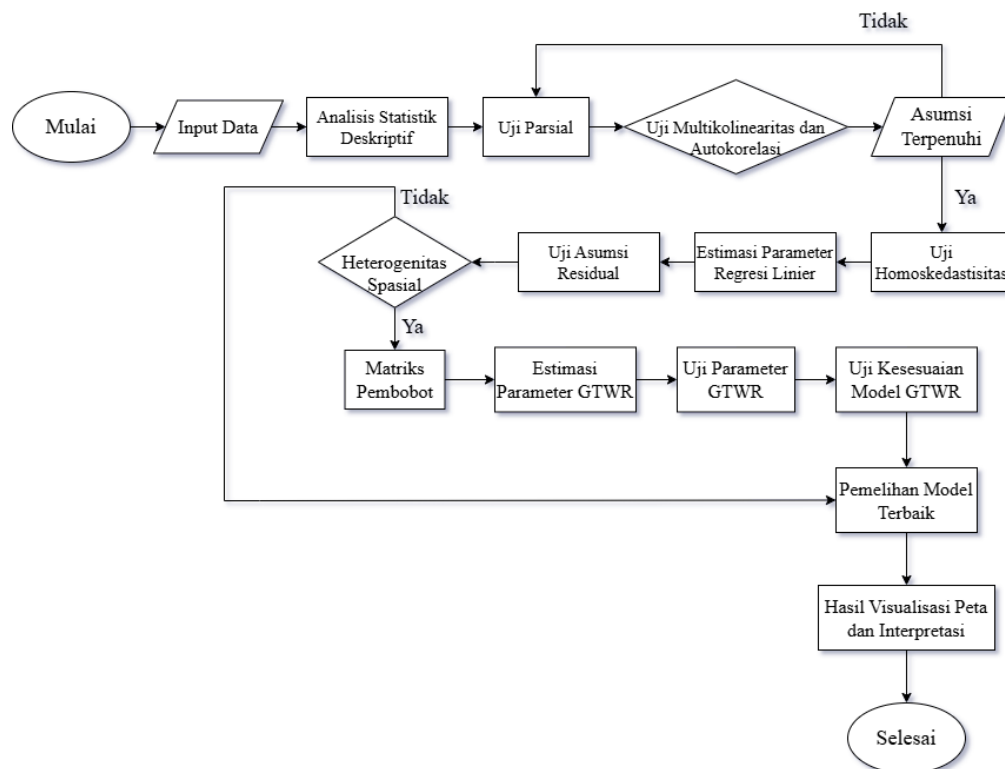
Penelitian selanjutnya juga dilakukan oleh Lasmi yang berjudul “*Pemodelan dan Pemetaan Kejadian Pneumonia pada Balita di Kota Bandung menggunakan Metode Geographically and Temporally Weighted Regression (GTWR)*” [9]. Penelitian ini membahas terkait pemodelan dan pemetaan kejadian *pneumonia* pada balita di Kota Bandung selama periode 2017–2020. Tujuan utamanya adalah mengidentifikasi faktor-faktor risiko yang memengaruhi penyebaran *pneumonia* pada balita dengan mempertimbangkan variasi spasial dan temporal. Untuk itu, digunakan metode GTWR, yang merupakan pengembangan dari GWR dengan penambahan aspek waktu dalam analisisnya. Hasil penelitian menunjukkan bahwa model GTWR dengan fungsi kernel eksponensial memberikan hasil yang optimal, ditunjukkan oleh nilai Pseudo R^2 sebesar 0,8783. Analisis ini memungkinkan identifikasi faktor-faktor signifikan yang memengaruhi kejadian *pneumonia* pada balita di setiap kecamatan di Kota Bandung untuk setiap tahunnya.

Dari beberapa penelitian terdahulu terlihat bahwa pendekatan analisis spasial dan spasio-temporal telah banyak digunakan untuk mengkaji berbagai isu kesehatan masyarakat. Terdapat penelitian yang menggunakan pendekatan GWGR dan GTWR pada kasus DBD di Bali, namun fokusnya terbatas pada periode 2014–2016 dan belum menyoroti aspek pemetaan risiko berbasis WebGIS. Selanjutnya, terdapat penelitian yang menggunakan GWR untuk menganalisis faktor spasial DBD di Pekanbaru, namun belum mempertimbangkan dinamika temporal. Sementara itu, penelitian Prayoga mengkaji *stunting* menggunakan *machine learning* dengan integrasi data satelit, sehingga berbeda konteks penyakit dan metode dari penelitian ini. Penelitian lainnya memang telah menerapkan GTWR, tetapi berbeda pada objek kajiannya adalah *pneumonia* pada balita di Kota Bandung.

Kebaruan penelitian ini adalah penerapan GTWR untuk menganalisis penyebaran kasus DBD di wilayah Jakarta Selatan dengan data terbaru tahun 2023–2024. Penelitian ini mengintegrasikan faktor lingkungan utama (suhu, kelembaban, curah hujan, dan kepadatan penduduk) ke dalam model spasio-temporal, sehingga mampu menangkap variasi lokal antar kecamatan dan pergeseran temporal antar bulan. Selain itu, hasil analisis divisualisasikan dalam bentuk peta risiko berbasis WebGIS, yang memberikan kontribusi praktis bagi pemerintah daerah dalam menentukan prioritas wilayah intervensi. Dengan demikian, penelitian ini melengkapi literatur sebelumnya dengan menghadirkan analisis spasio-temporal DBD yang lebih mutakhir, berbasis data lokal, serta aplikatif untuk pengendalian penyakit di tingkat mikro.

2. METODE PENELITIAN

Rancangan desain sistem analisis ini direpresentasikan dalam bentuk notasi *flowchart* untuk menggambarkan alur proses secara sistematis dan terarah seperti pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Input Data

Dataset yang digunakan dalam penelitian ini menggunakan data sekunder yang diperoleh dari Badan Pusat Statistika (BPS) dan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Data tersebut mencakup jumlah kasus DBD per kabupaten/kota, serta data lingkungan seperti suhu udara, kelembaban, curah hujan, dan kepadatan penduduk. Data ini digunakan sebagai input dalam analisis spasial dan temporal untuk mengkaji pengaruh faktor lingkungan terhadap persebaran kasus DBD di Jakarta Selatan. Selain itu, data spasial berupa batas wilayah administratif dan koordinat geografis dari masing-masing lokasi juga diperlukan untuk mendukung analisis berbasis geospasial.

2.2 Pre-Processing Data

Tahap ini merupakan proses persiapan data sebelum dilakukan analisis. Data yang telah dikumpulkan kemudian dibersihkan dari nilai hilang (*missing values*), kesalahan *input*, serta *outlier* yang dapat mempengaruhi hasil analisis. Selain itu, data diselaraskan secara spasial (format koordinat, bentuk peta) maupun temporal (format waktu, konsistensi periode pengamatan) sehingga sesuai dengan kebutuhan analisis menggunakan metode GTWR yang memerlukan ketepatan dalam skala ruang dan waktu.

2.3 Uji Parsial

Pada tahapan ini dilakukan uji parsial terhadap variabel-variabel independen untuk melihat hubungan awal dengan variabel dependen, yaitu jumlah kasus DBD. Uji ini dilakukan untuk menentukan masing-masing faktor lingkungan secara individu memiliki pengaruh signifikan. Jika ada variabel yang tidak signifikan secara statistik, maka variabel tersebut bisa dieliminasi dari model atau ditransformasikan agar lebih representatif [10].

Uji parsial biasanya dilakukan dengan menggunakan uji-t lokal yang mirip seperti pada regresi linear biasa, namun dihitung untuk setiap titik observasi. Interpretasi dari hasil uji t ini, membandingkan hasil nilai t dengan nilai kritis t dari distribusi t misalnya $t_{0.05, df}$. Atau langsung tertuju pada nilai p -value dari uji t yang diperiksa.

2.4 Uji Homoskedastisitas

Tahap ini dilakukan untuk memastikan bahwa varians residual model regresi bersifat konstan pada semua nilai prediktor. Uji ini penting untuk menjaga validitas inferensi statistik dari hasil model. Jika ditemukan gejala heteroskedastisitas (variens yang tidak konstan), maka diperlukan transformasi data atau pendekatan pemodelan lain yang lebih fleksibel.

Uji homoskedastisitas dilakukan dengan menggunakan Uji Breusch-Pagan untuk melihat varian residual yang tergantung pada variabel independen. Dengan rumus statistik Uji Breusch-Pagan sebagai berikut [11]:

$$BP = \frac{n \cdot R_{aux}^2}{2} \quad (1)$$

Dimana n = jumlah observasi dan R_{aux}^2 = koefisien determinasi dari regresi kuadrat residual terhadap variabel independen

2.5 Uji Asumsi Residual

Setelah parameter OLS diperoleh, dilakukan uji terhadap distribusi residual guna mengetahui apakah sisa-sisa prediksi dari model menyebar secara acak dan normal. Selain itu, dilakukan analisis visual maupun statistik untuk mendeteksi apakah terdapat pola spasial dalam residual, yang menunjukkan bahwa model linier biasa belum cukup menjelaskan keragaman data secara geografis dan waktu.

Uji asumsi residual meliputi beberapa asumsi lainnya seperti uji normalitas dan uji multikolinearitas. Asumsi ini tetap harus dipenuhi agar model regresi dapat digunakan. Uji normalitas residual bertujuan untuk memastikan bahwa distribusi residual mengikuti distribusi normal, yang dapat diuji menggunakan metode seperti histogram, P-Plot, atau uji Kolmogorov-Smirnov [12].

Sedangkan untuk uji multikolinearitas dilakukan untuk mendeteksi adanya hubungan linear yang kuat antara dua atau lebih variabel independen dalam model regresi. Multikolinearitas dapat menyebabkan masalah dalam estimasi koefisien regresi, seperti varians yang tinggi dan ketidakstabilan koefisien, yang pada gilirannya dapat mempengaruhi interpretasi dan prediksi model. Dengan melihat nilai VIF (*Variance Inflation Factor*) yang lebih besar dari 10 sering dianggap sebagai indikasi adanya multikolinearitas yang serius. Secara matematis VIF dirumuskan sebagai berikut [13]:

$$VIF = \frac{1}{1 - R_j^2} \quad (2)$$

Dengan nilai R_j^2 = koefisien determinasi antara variabel independent ke-j (x_j) dengan variabel independent lainnya.

2.6 Estimasi Parameter Regresi Linier

Setelah asumsi dasar sebelumnya telah terpenuhi, dilakukan estimasi parameter regresi linier dengan pendekatan *Ordinary Least Square* (OLS). Model OLS ini bertindak sebagai pembanding awal untuk melihat performa model regresi global terhadap data DBD dan faktor lingkungan tanpa mempertimbangkan variasi spasial dan temporal [14]. Model OLS bekerja dengan meminimalkan jumlah kuadrat selisih antaranilai observasi dengan nilai prediksi dan model. Model OLS dapat dituliskan dalam persamaan sebagai berikut [15]:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (3)$$

Dimana Y = Variabel dependen, X_1, X_2, \dots, X_k = Variabel independent, β_0 sebagai intercept (konstanta), sementara untuk β_1, \dots, β_k sebagai koefisien regresi untuk masing-masing variabel bebas dan ε merupakan error (residual)

2.7 Geographically and Temporally Weighted Regression (GTWR)

Metode GTWR merupakan pengembangan dari GWR dengan menambahkan dimensi waktu ke dalam analisis. GTWR digunakan untuk menganalisis hubungan antar variabel yang tidak hanya berbeda antar wilayah (spasial), tetapi juga berubah seiring waktu (temporal). Keunggulan GTWR adalah kemampuannya memberikan parameter regresi lokal yang bervariasi sesuai lokasi dan waktu, sehingga menghasilkan model yang lebih realistis pada data spasio-temporal [16].

Keunggulan GTWR dibandingkan GWR adalah kemampuannya memberikan estimasi parameter regresi lokal yang lebih adaptif, sehingga hasil analisis lebih sesuai dengan karakteristik data spasio-temporal yang kompleks. Hal ini terbukti pada penelitian yang menunjukkan GTWR lebih akurat dalam menjelaskan variasi spasio-temporal dibandingkan model global atau GWR. GTWR banyak digunakan dalam bidang kesehatan masyarakat karena mampu mengidentifikasi variasi risiko penyakit secara geografis dan waktu. Selain itu, interpretasi hasil GTWR dapat menjadi lebih sulit ketika jumlah variabel dan observasi sangat besar, karena setiap lokasi dan waktu memiliki nilai koefisien yang berbeda. Namun demikian, GTWR juga memiliki keterbatasan, antara lain membutuhkan data spasio-temporal yang lengkap dan merata, serta memerlukan komputasi yang lebih kompleks dibandingkan GWR [6].

Beberapa penelitian terdahulu menunjukkan efektivitas GTWR. Misalnya, *Lasmi dkk.* menggunakan GTWR untuk memodelkan kejadian pneumonia balita di Kota Bandung periode 2017–2020 dan memperoleh hasil yang lebih baik dibandingkan GWR. Penelitian *Oktarina dkk.* juga membandingkan GWR dan GTWR untuk pemodelan Indeks Pembangunan Manusia (IPM) di Provinsi Bengkulu, hasilnya GTWR lebih akurat karena mampu menangkap variasi temporal. Sementara itu, penelitian Nafan di Bali membuktikan bahwa GTWR lebih baik dibandingkan GWGR dalam menjelaskan faktor iklim yang memengaruhi insidensi DBD.

Dari penelitian-penelitian tersebut dapat disimpulkan bahwa GTWR unggul dibandingkan GWR dalam analisis data spasio-temporal, khususnya ketika terdapat variasi signifikan antar waktu. Kebaruan penelitian ini adalah penerapan GTWR pada kasus DBD di Jakarta Selatan dengan data terbaru tahun 2023–2024, yang sebelumnya belum pernah dilakukan. Hal ini membedakan studi ini dari penelitian terdahulu yang cenderung fokus pada wilayah lain (misalnya Bali, Bandung, atau Pekanbaru) atau hanya menggunakan pendekatan spasial tanpa memasukkan aspek temporal.

2.8 Uji Parameter GTWR

GTWR merupakan dari model GWR yang mengakomodasi adanya heterogenitas spasial (lokasi) dan heterogenitas temporal (waktu) yang tidak stasioner [17]. Namun, GTWR melakukan penggabungan unsur temporal dan spasial yang menggunakan matriks pembobot yang dapat mengidentifikasi keragaman spasial dan temporal. Pemodelan GTWR untuk p peubah prediktor dengan peubah respon pada koordinat (u_i, v_i, t_i) untuk setiap pengamatan dengan persamaan sebagai berikut.

$$\hat{\beta}(u_i, v_i, t_i) = [X^T W(u_i, v_i, t_i) X]^{-1} X^T W(u_i, v_i, t_i) Y \quad (4)$$

Vektor dan matriks yang memuat pada persamaan (1) adalah sebagai berikut.

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} \quad (5)$$

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1q} \\ 1 & x_{21} & x_{22} & \dots & x_{2q} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nq} \end{pmatrix} \quad (6)$$

$$\hat{\beta}(u_i, v_i, t_i) = \begin{pmatrix} \beta_0(u_i, v_i, t_i) \\ \beta_1(u_i, v_i, t_i) \\ \vdots \\ \beta_q(u_i, v_i, t_i) \end{pmatrix} \quad (7)$$

Matriks $W(u_i, v_i, t_i)$ adalah matriks pembobot spasial temporal pada lokasi ke- i dan waktu ke- t yang disusun *bandwidth* spasial temporal optimum dengan metode *Cross Validation*. Pendugaan parameter pada GTWR dapat dituliskan Persamaan (2) sebagai berikut.

$$y_i = \beta_0(u_i, v_i, t_i) \sum_{k=1}^p \beta_k(u_i, v_i, t_i) x_{ik} + \varepsilon_i \quad (8)$$

Dimana y_i merupakan peubah respon pada lokasi ke- i , (u_i, v_i, t_i) sebagai koordinat geografis dan waktu lokasi ke- i , sementara untuk $\beta_0(u_i, v_i, t_i)$ merupakan nilai *intercept* model GTWR, dan ε_i sebagai error pengamatan ke- i

2.9 Uji Kesesuaian Model GTWR

Pengujian kesesuaian model dilakukan untuk mengetahui adanya perbedaan antara model regresi global dan model GTWR. Uji ini bertujuan untuk memastikan bahwa model GTWR memberikan hasil yang lebih baik dalam menangkap variasi spasial dan temporal dibandingkan dengan model regresi global yang bersifat homogen di seluruh wilayah dan waktu [18] [19]. Pengujian kesesuaian model GTWR ini tidak berbeda pada pengujian kesesuaian model GWR dengan menggunakan deviance atau nilai AICc sebagai dasar perbandingan. Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut:

1. H_0 : Tidak ada perbedaan yang signifikan antara model regresi global dan GTWR
2. H_1 : Terdapat perbedaan signifikan antara model regresi global dan GTWR

Ketika hasil pengujian menunjukkan bahwa nilai deviance atau AICc model GTWR lebih rendah secara signifikan dibandingkan model regresi global, maka H_0 ditolak yang artinya model GTWR lebih sesuai untuk digunakan dalam menganalisis pengaruh faktor lingkungan terhadap kasus DBD di Jakarta Selatan.

2.10 Hasil Visualisasi Peta

Tahapan ini menyajikan sebuah visualisasi peta dari hasil model GTWR berbasis WebGIS. Visualisasi ini menggunakan sebuah bantuan file GeoJSON untuk menggambarkan batasan wilayah pada kabupaten/kota di Jakarta Selatan. File GeoJSON tersebut kemudian diimpor ke dalam Python guna dilakukan penggabungan (*join*) dengan data hasil estimasi GTWR, seperti nilai koefisien, tingkat signifikansi, dan nilai residual untuk setiap kabupaten/kota. Setelah digabungkan data divisualisasikan menggunakan Python seperti Folium, Geopandas, atau Plotly sehingga menghasilkan peta interaktif yang memperlihatkan distribusi spasial dari pengaruh masing-masing variabel independen terhadap jumlah kasus DBD. Sehingga adanya visualisasi berbasis WebGIS ini dapat memahami distribusi dari pengaruh faktor lingkungan dan mengidentifikasi wilayah-wilayah yang memiliki risiko tinggi berdasarkan hasil analisis GTWR [20].

3. HASIL DAN PEMBAHASAN

Pada bagian hasil dan pembahasan ini menjelaskan secara rinci tahapan proses klasifikasi yang diterapkan dalam analisis spasial-temporal untuk dilakukan pemetaan pada persebaran kasus DBD di wilayah Jakarta Selatan. Proses ini mencakup tahapan *pre-processing* data, penerapan algoritma klasifikasi, dan interpretasi hasil prediksi yang dihasilkan. Hasil prediksi ini akan memberikan gambaran mengenai wilayah-wilayah yang memiliki tingkat kerentanan tinggi terhadap kasus DBD.

3.1. Pengumpulan Data

Pengumpulan data penelitian ini bertujuan untuk memperoleh informasi mengenai jumlah kasus DBD dan variabel lingkungan yang diduga berpengaruh terhadap penyebaran penyakit tersebut. Data ini diperoleh dari situs web resmi Dinas Kesehatan Provinsi DKI Jakarta, yang juga mencakup kepadatan penduduk di tingkat kecamatan. Untuk saat ini, informasi iklim seperti kelembaban maksimum dan minimum, curah hujan, dan suhu maksimum dan minimum dikumpulkan dari BMKG. Data untuk wilayah Jakarta Selatan dari

tahun 2023 hingga 2024 dikumpulkan dan disajikan dalam bentuk Tabel 1. Selanjutnya, analisis statistik spasial dilakukan.

Tabel 1. Data Kasus DBD

Tahun	Kecamatan	Kasus DBD	Kepadatan Penduduk	Kelembaban <i>Max</i>	Kelembaban <i>Min</i>	Curah Hujan	Suhu <i>Max</i>	Suhu <i>Min</i>
2023	Cilandak	9	138178.28	99	77	621.9	32.6	22.6
2023	Jagakarsa	69	93426.78	99	77	621.9	32.6	22.6
...
2024	Setiabudi	3	191021.60	95	47	211	34.8	24.1
2024	Tebet	9	205193.21	95	47	211	34.8	24.1

3.2. Pre-Processing Data

Tahap *pre-processing* data dimulai dengan proses deteksi *outlier*, setelah dilakukan deteksi *outlier* pada data tersebut teridentifikasi sebanyak 85 data sebagai *outlier*. *Outlier* tersebut dapat mempengaruhi hasil analisis dan pemodelan sehingga perlu diperhatikan secara khusus. Dalam penanganan *outlier* dilakukan transformasi data pada variabel dependen untuk mengurangi pengaruh ekstrem *outlier* terhadap analisis statistik dan pemodelan. Transformasi yang digunakan adalah transformasi alogaritma (*log*) karena mampu memadatkan rentang data, menstabilkan varians, serta mengurangi *skewness*. Berikut Tabel 2 hasil transformasi data pada variabel dependen.

Tabel 2. Transformasi Data

Kasus DBD	Kasus DBD Log
9	2.303
69	4.248
33	3.526
71	4.277
17	2.890

3.3. Analisis Statistika Deskriptif

Analisis Statistika Deskriptif Tabel 3 ini untuk mengetahui gambaran umum karakteristik data yang digunakan dalam penelitian. Dalam analisis ini, masing-masing variabel, baik variabel dependen maupun independen, dihitung nilai minimum, maksimum, rata-rata (*mean*), standar deviasi, dan sebaran data. Dengan menggunakan analisis deskriptif, peneliti dapat memahami distribusi data, menemukan nilai ekstrim atau *outlier*, dan menilai kecenderungan pusat dan keragaman.

Tabel 3. Statistika Deskriptif

Variabel	Rata-Rata	Minimum	Maksimum	STD
Kasus DBD (Y)	34.671	0	241	0.501
Kepadatan Penduduk (X_1)	173384.26	18058.31	414460.1	3.459
Kelembaban <i>Max</i> (X_2)	91.596	82	100	38.995
Kelembaban <i>Min</i> (X_3)	57.958	31	77	83820.1
Curah Hujan (X_4)	237.804	39	1075	4.784
Suhu <i>Max</i> (X_5)	34.707	32.6	37	11.22
Suhu <i>Min</i> (X_6)	23.562	22.4	25	234.

3.4. Uji Normalitas

Tahapan pada uji normalitas ini meliputi identifikasi residual dari model yang kemudian dilakukan pengujian statistika menggunakan metode Shapiro-Wilk.

Hipotesis:

H_0 = Berdistribusi normal


H_1 = Tidak berdistribusi normal

Jika $p\text{-value} > 0.05$, maka H_0 diterima yang berarti data berdistribusi normal, sedangkan $p\text{-value} < 0.05$ maka H_0 ditolak artinya data tidak berdistribusi normal.

Tabel 4. Uji Normalitas

Uji Shapiro-Wilk	0.989
$p\text{-value}$	0.765

Berdasarkan pada Tabel 4, $p\text{-value} > 0.05$, maka H_0 diterima yang artinya data berdistribusi normal (lihat Gambar 2). Sehingga asumsi normalitas terpenuhi dan data dapat digunakan untuk analisis tahap selanjutnya.



Gambar 2. Sebaran Distribusi

3.5. Uji Multikolinieritas dan Autokorelasi

Multikolinieritas merupakan kondisi di mana terdapat hubungan korelasi yang tinggi antara dua atau lebih variabel independen dalam suatu model regresi. Kondisi ini membuat sulit untuk mengetahui pengaruh masing-masing variabel terhadap variabel dependen secara terpisah. Hal ini dapat menyebabkan hasil estimasi model tidak stabil dan interpretasi yang salah tentang koefisien regresi. Sebelum menggunakan metode GTWR, pengujian ini dilakukan sebagai langkah awal untuk memenuhi asumsi. Tidak adanya multikolinearitas antar variabel independen adalah asumsi penting yang harus diuji. Nilai Variasi Inflasi *Factor* (VIF) dari masing-masing variabel digunakan untuk menguji multikolinearitas. Nilai VIF suatu variabel dianggap memiliki indikasi multikolinearitas yang kuat dan dapat mempengaruhi validitas model. Hasil perhitungan nilai VIF untuk setiap variabel independen yang digunakan dalam penelitian ini disajikan pada Tabel 5.

Tabel 5. Hasil VIF

Variabel	VIF
Kepadatan Penduduk	1.154709
Kelembaban <i>Max</i>	5.042454
Kelembaban <i>Min</i>	6.015449
Curah Hujan	2.052464
Suhu <i>Max</i>	6.309070
Suhu <i>Min</i>	1.897787

Berdasarkan Tabel 5, setiap variabel independen memiliki nilai VIF > 10 , menurut hasil perhitungan nilai VIF yang ditampilkan pada tabel di atas. Hal ini menunjukkan tidak ada bukti multikolinearitas yang signifikan di antara variabel independen model. Oleh karena itu, keenam variabel tersebut telah memenuhi salah satu asumsi penting dalam pemodelan regresi, dapat disimpulkan bahwa variabel independen di atas dapat di analisis lebih lanjut menggunakan metode GTWR.

Autokorelasi Durbin Watson ini dilakukan untuk menentukan apakah ada atau tidaknya hubungan (korelasi) antara residual (galat) pada suatu peristiwa dalam model regresi dengan residual pada peristiwa sebelumnya. Jika ada autokorelasi yang signifikan, terutama jika terjadi pada data runtut waktu (*time series*) atau data spasial, ini dapat menunjukkan bahwa asumsi klasik regresi yang menyatakan bahwa residual harus bersifat independen. Nilai statistik Durbin-Watson berkisar antara 0 dan 4 nilai yang lebih rendah dari 0 menunjukkan autokorelasi yang tidak ada, yang lebih tinggi dari 4 menunjukkan autokorelasi yang negatif. Oleh karena itu, sebelum analisis dilanjutkan, uji ini sangat penting untuk memastikan validitas model.

Hipotesis:

H_0 = Tidak ada autokorelasi pada residual (residual bersifat independen)

H_1 = Ada autokorelasi pada residual

Tabel 6. Nilai Durbin-Watson

	Nilai
Durbin-Watson	1.388

Hasil uji pada Tabel 6 menunjukkan bahwa nilai Durbin-Watson adalah 1.388, yang lebih rendah dari nilai netral 2. Ini mengindikasikan bahwa ada autokorelasi positif di antara residual model regresi. Akibatnya, hipotesis nol (H_0) ditolak, sehingga terdapat pola keterkaitan atau hubungan antar residual yang berdekatan secara berurutan.

3.6. Uji Homoskedastisitas

Tahapan uji homoskedastisitas ini salah satu asumsi klasik dalam analisis regresi adalah bahwa varians dari residual, atau galat, harus konstan pada semua tingkat nilai variabel independen. Jika asumsi ini terpenuhi, maka model regresi dianggap stabil dan dapat menghasilkan estimasi yang tidak bias. Sebaliknya, jika terjadi heteroskedastisitas, atau varian residual yang tidak konstan, maka model regresi dapat menghasilkan estimasi yang tidak akurat, terutama dalam hal perhitungan standar error dan uji signifikansi kovarian.

Hipotesis:

H_0 = Terjadi homoskedastisitas

H_1 = Terjadi heteroskedastisitas

Jika $p\text{-value} > 0.05$, maka H_0 diterima artinya tidak terjadi heteroskedastisitas, sedangkan $p\text{-value} < 0.05$ maka H_0 ditolak artinya terjadi heteroskedastisitas.

Tabel 7. Uji Breusch-Pagan

	Nilai
<i>Lagrange Multiplier Statistic</i>	11.718
<i>p-value</i>	0.1102
<i>f-statistic</i>	1.701
<i>f p-value</i>	0.1095

Berdasarkan Tabel 7, hasil uji Breusch-Pagan menunjukkan $p\text{-value} > 0.05$ maka H_0 diterima, sehingga pada data tidak terjadi heteroskedastisitas atau terjadi homoskedastisitas.

3.7. Estimasi Parameter Regresi Linier (OLS)

Pada tahapan ini, dilakukan estimasi parameter menggunakan metode OLS untuk mengetahui hubungan antara variabel independen terhadap variabel dependen. Estimasi ini menghasilkan nilai koefisien regresi, standar error, nilai $t\text{-statistic}$, dan $p\text{-value}$ yang berguna dalam pengujian signifikansi kontribusi masing-masing variabel terhadap model.

Tabel 8. Goodness-of-Fit

	Nilai
<i>R-squared</i>	0.321
<i>Adj. R-squared</i>	0.301
<i>F-statistic</i>	15.69

Berdasarkan Tabel 8, nilai *R-squared* 32.1% artinya variasi dalam kasus DBD dapat dijelaskan oleh variabel-variabel independen dalam model, sisanya 97.9% dijelaskan oleh faktor lain di luar model. Kemudian *Adj. R-squared* sebesar 0.301 artinya masih menunjukkan bahwa model memiliki kemampuan penjelasan moderat, dan *F-statistic* sebesar 15.69, hal tersebut menunjukkan bahwa model secara keseluruhan signifikan artinya minimal ada satu variabel independen yang berpengaruh signifikan terhadap kasus DBD. Pada OLS juga terdapat estimasi parameter dalam bentuk nilai koefisien untuk setiap variabel independen. Berikut Tabel 9 estimasi parameter regresi linier.

Tabel 9. Estimasi Parameter Regresi Linier

	Coef
<i>Const</i>	-2.4443
Kepadatan Penduduk	-9.1×10^{-7}
Kelembaban <i>Max</i>	0.1022
Kelembaban <i>Min</i>	-0.0470
Curah Hujan	-0.0010
Suhu <i>Max</i>	-0.1822
Suhu <i>Min</i>	0.2733
<i>Time</i>	-0.0704

Berdasarkan Tabel 9, nilai estimasi parameter pada variabel independen di atas dapat disimpulkan bahwa variabel kelembaban maksimum, kelembaban minimum, curah hujan, suhu minimum, dan waktu memiliki koefisien yang signifikan terhadap kasus DBD. Nilai koefisien positif menunjukkan hubungan searah, sedangkan koefisien negatif menunjukkan hubungan berlawanan. Sementara itu, pada variabel kepadatan penduduk dan suhu maksimum tidak signifikan secara statistik sehingga tidak memberikan pengaruh terhadap variasi kasus DBD dalam model.

3.8. Autokorelasi Spasial

Tahapan autokorelasi spasial ini bertujuan untuk mengidentifikasi terhadap pola keterkaitan geografis (spasial) diantara Lokasi-lokasi pengamatan. Uji yang digunakan pada tahapan ini adalah Moran's I yang dapat mendeteksi nilai variabel cenderung membentuk *cluster* atau tersebar secara acak di wilayah Jakarta Selatan.

Hipotesis:

H_0 = Tidak ada autokorelasi spasial (wilayah kecamatan di Jakarta Selatan tidak berkaitan dengan nilai variabel dilokasi sekitarnya)

H_1 = Ada autokorelasi spasial (wilayah kecamatan di Jakarta Selatan berkaitan dengan nilai variabel dilokasi sekitarnya)

1. Autokorelasi positif: Wilayah kecamatan di Jakarta Selatan yang berdekatan memiliki nilai yang mirip.
2. Autokorelasi negatif: Wilayah kecamatan di Jakarta Selatan yang berdekatan memiliki nilai yang sangat berbeda.

Tabel 10. Perhitungan Indeks Moran's I

Variabel	Moran's I	<i>p-value</i>
Kepadatan Penduduk (x_1)	0.6334	0.0010
Kelembaban <i>Max</i> (x_2)	0.6344	0.0010
Kelembaban <i>Min</i> (x_3)	-0.0451	0.0980
Curah Hujan (x_4)	-0.0528	0.0740
Suhu <i>Max</i> (x_5)	-0.0489	0.0580
Suhu <i>Min</i> (x_6)	-0.0442	0.1010
Time (x_7)	-0.0406	0.1320

Berdasarkan Tabel 10, hasil perhitungan indeks Moran's I menunjukkan bahwa variabel kepadatan penduduk (x_1) dan kelembaban *max* (x_2) memiliki autokorelasi positif yang signifikan dengan nilai *p-value* sebesar 0.001 artinya persebarannya tidak acak secara spasial. Sementara itu, variabel kelembaban *min* (x_3), curah hujan (x_4), suhu *max* (x_5), suhu *min* (x_6), dan time (x_7) memiliki *p-value* diatas 0.05 sehingga tidak menunjukkan autokorelasi yang signifikan. Hal ini mengindikasikan bahwa hanya sebagian variabel yang memiliki pola spasial yang terstruktur dalam wilayah kecamatan di Jakarta Selatan.

3.9. Uji Parameter Geographically & Temporally Wighted Regression (GTWR)

Tahapan uji parameter lokal GTWR ini dilakukan untuk mengetahui seberapa besar pengaruh masing-masing variabel independen terhadap variabel dependen pada setiap wilayah dan waktu secara spesifik. Berikut hasil koefisien lokal pada Tabel 11.

Tabel 11. Koefisien Lokal

Kecamatan	Koef. Kepadatan Penduduk	Koef. Kelembaban <i>Max</i>	Koef. Kelembaban <i>Min</i>	Koef. Curah Hujan	Koef. Suhu <i>Max</i>	Koef. Suhu <i>Min</i>	Time
Cilandak	1.31×10^6	0.0914	-0.0482	-0.0003	-0.1549	0.4228	-0.0341
Jagakarsa	-1.82×10^6	0.0862	-0.0257	-0.0009	-0.1891	0.2946	-0.0464
Kebayoran Baru	4.23×10^6	0.1165	-0.0616	-0.0006	-0.0983	0.3069	-0.0897
Kebayoran Lama	5.90×10^6	0.1247	-0.0524	-0.0007	-0.0676	0.2930	-0.0795
Mampang Prapatan	2.02×10^6	0.1048	-0.0689	-0.0006	-0.1911	0.3791	-0.0896

Berdasarkan Tabel 11, koefisien lokal GTWR menunjukkan bahwa pengaruh masing-masing variabel berbeda antar kecamatan. Beberapa variabel seperti kelembaban maksimum dan suhu minimum cenderung positif dan konsisten, sedangkan variabel kepadatan penduduk dan curah hujan memberikan pengaruh yang

lebih bervariasi. Sehingga dapat disimpulkan bahwa terdapat heterogenitas spasial dan temporal dalam faktor-faktor yang mempengaruhi kasus DBD di wilayah Jakarta Selatan.

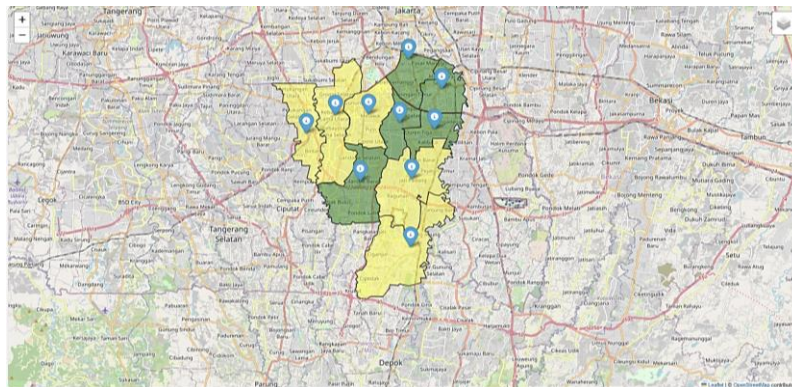
Evaluasi model GTWR ini dilakukan untuk menilai seberapa baik model dalam menjelaskan variasi spasial dan temporal dari kasus DBD. Evaluasi dilakukan dengan membandingkan nilai statistik *R-squared* (R^2), *Adjusted R-squared*, dan AICc dari model GTWR terhadap model GWR. Semakin tinggi nilai R^2 dan semakin rendah nilai AICc, maka model GTWR dianggap memiliki kinerja yang lebih baik. Berikut hasil evaluasi model GTWR pada Tabel 12.

Tabel 12. Evaluasi Model GTWR

	Nilai
<i>R-squared</i> (R^2)	0.5697
<i>Adjusted R-squared</i>	0.485
AICc	556.766

Berdasarkan Tabel 12, model GTWR menunjukkan R – square sebesar 0,5697 dan Adjusted R – Square 0,4485 yang mengindikasikan bahwa model ini mampu menjelaskan sekitar 48% sampai 57% variasi kasus DBD setelah memperhitungkan kompleksitas variabel. Selain itu, nilai AICc sebesar 556,766 lebih rendah dibandingkan AICc model OLS (selisih > 3) sehingga model GTWR dianggap lebih baik secara statistik karena memberikan keseimbangan antara ketepatan (fit) dan kesederhanaan. Hal ini sejalan dengan penelitian penelitian sebelumnya mengenai GWR pada kasus DBD di Indonesia yang menunjukkan nilai R^2 sebesar 55,7% lebih tinggi dibandingkan model regresi global, sehingga membuktikan bahwa pendekatan spasial memberikan kinerja lebih baik dalam menjelaskan variasi kasus penyakit menular dibandingkan model global [5].

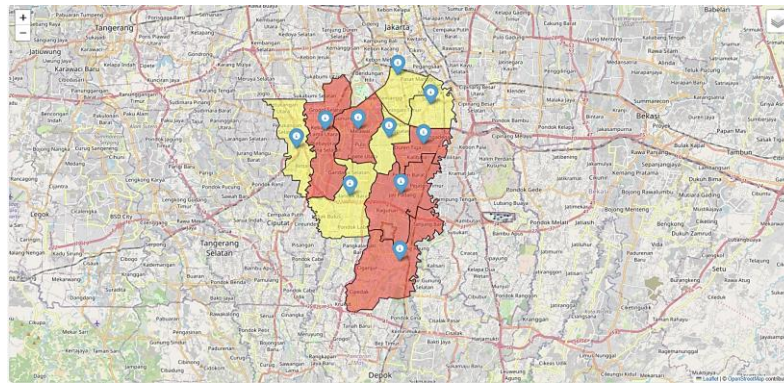
3.10. Peta Hasil Prediksi Persebaran DBD



Gambar 3. Kasus DBD Tahun 2023


Berdasarkan Gambar 3 tersebut menggambarkan hasil prediksi spasial kasus DBD tahun 2023 di wilayah Jakarta Selatan berdasarkan tingkat keparahan kasus pada masing-masing kecamatan. Warna hijau menunjukkan wilayah dengan prediksi kasus yang rendah, sementara warna kuning menunjukkan prediksi kasus yang sedang. Dari visualisasi terlihat bahwa kecamatan-kecamatan di bagian utara dan tengah Jakarta Selatan, seperti Setiabudi, Tebet, dan Pancoran, cenderung memiliki tingkat kasus DBD yang lebih rendah. Sebaliknya, kecamatan di bagian selatan dan barat daya seperti Jagakarsa, Cilandak, dan Kebayoran Lama masuk dalam kategori kuning, yang mengindikasikan intensitas kasus yang lebih tinggi dibanding wilayah lainnya. Dengan demikian, dapat disimpulkan bahwa terdapat heterogenitas spasial dalam persebaran kasus DBD dan wilayah dengan kategori kuning dapat dijadikan prioritas utama dalam upaya pengendalian dan pencegahan penyakit.

Berdasarkan Gambar 4 di atas menunjukkan hasil visualisasi prediksi kasus DBD tahun 2024 di wilayah Jakarta Selatan. Terlihat bahwa wilayah selatan dan tengah Jakarta Selatan, seperti Jagakarsa, Cilandak, dan Mampang Prapatan, didominasi oleh warna merah, yang menunjukkan bahwa daerah-daerah ini memiliki prediksi kasus DBD yang tinggi. Sementara itu, wilayah utara dan sebagian barat seperti Kebayoran Lama, Kebayoran Baru, serta Pesanggrahan cenderung berada dalam kategori sedang hingga rendah (kuning). Perbedaan warna ini mengindikasikan adanya heterogenitas spasial yang kuat dalam distribusi prediksi kasus DBD, dimana wilayah selatan menunjukkan tingkat risiko yang lebih tinggi dibandingkan wilayah lainnya. Sehingga perlunya difokuskan dalam pencegahan dan intervensi kesehatan masyarakat dengan memprioritaskan pada wilayah dengan warna merah.



Gambar 4. Kasus DBD Tahun 2024

3.11. Tren Prediksi Persebaran DBD



Gambar 5. Tren Prediksi Persebaran DBD

Berdasarkan Gambar 5 diatas, hasil visualisasi menunjukkan adanya fluktuasi musiman yang cukup jelas pada tren prediksi kasus DBD selama periode 2023 sampai 2024. Prediksi menunjukkan peningkatan kasus yang signifikan pada awal tahun terutama sekitar bulan Maret sampai April pada tahun 2023 dan 2024. Selain itu, lonjakan kasus juga terlihat pada pertengahan tahun 2024 yaitu sekitar bulan Juni sampai Juli. Sebaliknya terjadi penurunan tajam pada bulan Oktober di kedua tahun yang berkaitan dengan musim kemarau atau perubahan iklim seperti dibuktikan pada variabel independen yaitu kelembaban, curah hujan, dan suhu. Pada kelembaban di bulan Januari sampai Juli rata-rata lebih lembab daripada bulan lainnya, curah hujan di bulan Januari sampai Juli juga lebih tinggi dari bulan lainnya, dan suhu juga lebih rendah pada bulan tersebut, sehingga hal tersebut juga mendukung dalam mempengaruhi penyebaran nyamuk DBD.

4. KESIMPULAN

Penelitian ini berhasil mengidentifikasi pola spasial dan temporal kasus DBD di wilayah Jakarta Selatan dengan menggunakan pendekatan model GTWR. Metode ini memungkinkan analisis yang mempertimbangkan perbedaan pengaruh variabel lingkungan (seperti suhu, kelembaban, dan curah hujan) secara lokal (antar-kecamatan) dan dinamis dalam waktu (tahun dan bulan). Hasil uji parameter lokal menunjukkan bahwa setiap variabel memiliki pengaruh yang berbeda-beda di setiap kecamatan, baik dari segi arah maupun besar pengaruhnya terhadap jumlah kasus DBD. Beberapa variabel seperti kelembaban maksimum dan suhu minimum cenderung memberikan pengaruh positif yang konsisten terhadap peningkatan kasus DBD di sebagian besar wilayah. Sebaliknya, curah hujan dan kepadatan penduduk menunjukkan pengaruh yang bervariasi dan tidak selalu signifikan secara statistik. Evaluasi model menunjukkan nilai *R-squared* sebesar 0.5697, yang menandakan bahwa sekitar 56.97% variasi kasus DBD dapat dijelaskan oleh model GTWR, dan nilai AIC sebesar 556.766 menunjukkan tingkat kelayakan model yang cukup baik untuk data spasio-temporal. Hasil visualisasi peta prediksi menunjukkan adanya konsentrasi risiko tinggi di wilayah selatan dan tengah Jakarta Selatan seperti Jagakarsa, Cilandak, dan Mampang Prapatan, yang ditandai dengan kategori warna merah. Tren musiman juga tampak jelas, di mana kasus DBD cenderung meningkat pada awal dan pertengahan tahun, serta menurun saat musim kemarau sekitar bulan Oktober. Secara keseluruhan, model GTWR terbukti efektif dalam menangkap dinamika spasio-temporal kasus DBD, dan dapat menjadi dasar pengambilan kebijakan yang lebih tepat sasaran secara geografis dan waktu, terutama untuk intervensi

dini di wilayah-wilayah dengan prediksi risiko tinggi. Penelitian ini juga menegaskan pentingnya integrasi data lingkungan dan spasial dalam pengelolaan penyakit berbasis wilayah seperti DBD.

REFERENSI

- [1] R. Toni, "Kasus DBD di Jaksel Turun Dibandingkan Tahun Lalu," Berita Jakarta. [Online]. Available: <https://www.beritajakarta.id/read/143831/kasus-dbd-di-jaksel-turun-dibandingkan-tahun-lalu#:~:text=Kasus Demam Berdarah Dengue %28DBD%29 di Jakarta Selatan,DBD. %22Upaya preventif mencegah DBD terus kita lakukan%22>
- [2] K. Khairinnisa, Y. Fauzi, and E. Nugraheni, "Analisis Spasio-Temporal Kondisi Iklim dan Jumlah Kejadian Demam Berdarah Dengue (DBD) Tahun 2012-2021 di Bengkulu," *J. Kesehat. Lingkung. Indones.*, vol. 24, no. 2, pp. 136–144, 2025, doi: 10.14710/jkli.67945.
- [3] R. Pakaya, L. Lazuardi, and H. Nirwati, "Analisis spasial faktor lingkungan kejadian demam berdarah dengue (DBD) di Limboto Gorontalo," *J. Community Med. Public Heal.*, vol. 35, no. 9, pp. 315–322, 2019, [Online]. Available: <https://journal.ugm.ac.id/bkm/article/view/50492/31711>
- [4] A. Choiruni and H. Kusnanto, "Pola Spasial Temporal Demam Berdarah Dengue (DBD) di Kecamatan Tegalrejo Kota Yogyakarta Tahun 2016," *J. Inf. Syst. Public Heal.*, vol. 4, no. 1, pp. 80–84, 2019.
- [5] K. Amelia, L. O. Asril, and L. Febrianti, "Modeling the Incident Rate of Dengue Hemorrhagic Fever in Indonesia Related to Environmental Factors Using the Geographically Weighted Regression (GWR) Method," *Ekol. J. Ilm. Ilmu Dasar dan Lingkung. Hidup*, vol. 20, no. 2, pp. 64–73, 2020.
- [6] C. R. Oktarina, J. Rizal, F. Faisal, Q. L. Tasyah, and S. C. Pratiwi, "Pemodelan IPM di Provinsi Bengkulu dengan Pendekatan Metode Geographically Weighted Regression (GWR) dan Geographically Temporally Weighted Regression (GTWR)," *J. EurekaMatika*, vol. 12, no. 1, pp. 23–34, 2024.
- [7] E. A. Giofandi, P. Purwantiningrum, F. Madino, and A. Lumbantobing, "Analisis Faktor Spasial Terhadap Kejadian Demam Berdarah Dengue Menggunakan Pendekatan Geographically Weighted Regression di Kota Pekanbaru, Provinsi Riau," *J. Ilmu Lingkung.*, vol. 22, no. 1, pp. 50–59, 2023, doi: 10.14710/jil.22.1.50-59.
- [8] S. W. Prayoga and S. Pramana, "Pemetaan Kejadian Balita Stunting Melalui Integrasi Citra Satelit Multisumber dan Official Statistics di Provinsi Nusa Tenggara Timur Menggunakan Machine Learning," *Pros. Semin. Nas. Sains Data*, vol. 4, no. 1, pp. 434–444, 2024, doi: 10.33005/senada.v4i1.245.
- [9] P. A. Lestari, N. A. Fajar, Y. Windusari, Novrikasari, and E. Sunarsih, "Faktor Pengaruh Kesehatan Lingkungan terhadap Kejadian Demam Berdarah Danguue (DBD) di Wilayah Endemis: Systematic Literature Review," *Heal. Inf. J. Penelit.*, vol. 15, no. 3, pp. 1–10, 2023.
- [10] Rosmalawaty Sattuung et al., "Journal of Accounting Finance (JAF)," *Pengaruh Persepsi Keadilan Pajak Terhadap Kepatuhan Wajib Pajak Badan Dimasa Pandemic Covid-19 Tahun 2020*, vol. 1, no. September 2021, pp. 144–154, 2023.
- [11] G. P. Lasabuda and M. Mangantar, "Pengaruh Struktur Modal, Likuiditas, Dan Profitabilitas Terhadap Nilai Perusahaan Pada Perusahaan Subsektor Otomotif Yang Terdaftar Di Bursa Efek Indonesia 2017-2020," *J. EMBA J. Ris. Ekon. Manajemen, Bisnis dan Akunt.*, vol. 10, no. 2, p. 337, 2022, doi: 10.35794/emba.v10i2.40256.
- [12] N. Rida Astridawati Silalahi, Adinda Aulia Hafsa, Dina Situmorang and D. P. O. Emaninta Br Ginting, Ari Bayuma Girsang, Mikhael Martin, Elvi Febriyansi, "Hasil perhitungan Asumsi Klasik: Tentang Uji Autokorelaksi, Nomalitas, dan Heterokeditas," vol. 8, no. 12, pp. 218–225, 2024.
- [13] E. A. Sari, H. I. Rahma, M. R. Firdaus, W. WInarto, Y. Indiyani, and R. Nooraeni, "Perbandingan regresi OLS dan robust MM-Estimation dalam kasus DBD di Indonesia 2018," *J. Educ. Dev.*, vol. 8, no. 2, pp. 68–74, 2020, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jbmstr/article/view/7350>
- [14] A. S. Rahardja, "Pengaruh Teknologi Big Data terhadap Financial Performance dan Competitive Advantage Studi pada Perusahaan Go Public di Indonesia Sektor Perbankan," *Innov. Technol. Methodical Res. J.*, vol. 2, no. 2, p. 13, 2024, doi: 10.47134/innovative.v2i2.24.
- [15] A. Praditya, P. R. Arum, and A. Fadlurohman, "Penerapan Geographically and Temporally Weighted Regression (GTWR) dalam Menganalisis Tingkat Pengangguran Terbuka di Indonesia," vol. 2025, no. Senada, pp. 326–335, 2025.
- [16] X. X. ZHU, S. W. WANG, Y. F. LI, Y. W. ZHANG, X. M. SU, and X. T. ZHAO, "Geographically and Temporally Weighted Regression in Assessing Dengue Fever Spread Factors in Yunnan Border Regions," *Biomed. Environ. Sci.*, vol. 37, no. 5, pp. 511–520, 2024, doi: 10.3967/bes2024.056.
- [17] Debataraja et al., "Penerapan Model Geographically Dan Temporally Weighted Regression Pada Kecelakaan Lalu Lintas," *J. Siger Mat.*, vol. 2, no. 1, pp. 19–24, 2021, doi: 10.23960/jsm.v2i1.2751.
- [18] C. Objects, I. Indonesia, M. N. Sulistyawati, T. Aditya, and P. B. Santosa, "Journal of Geospatial

- Information Science and Engineering Development of Spatio-Temporal Database Prototype for Management of,” vol. 1, no. 2, pp. 94–103, 2019.
- [19] F. I. Permatasari, “Math Unesa,” *J. Ilm. Mat.*, vol. 13, no. 1, pp. 2301–9115, 2025, [Online]. Available: <https://media.neliti.com/media/publications/249234-model-infeksi-hiv-dengan-pengaruh-percob-b7e3cd43.pdf>
- [20] B. R. Fitriana, “Hubungan Faktor Suhu Dengan Kasus Demam Berdarah Dengue (Dbd) Di Kecamatan Sawahan Surabaya,” *Indones. J. Public Heal.*, vol. 13, no. 1, p. 85, 2019, doi: 10.20473/ijph.v13i1.2018.85-97.