

# Faktor Pemengaruh Tingkat Keparahan Kebakaran Hutan di Kalimantan Selatan pada Tahun 2023

## Menggunakan Geographically Weighted Regression

*Factors Influencing Forest Fire Severity in South Kalimantan on 2023*

*using Geographically Weighted Regression*

M. Naswan Izzudin Akmal, Dwi Arman Prasetya<sup>2</sup>, Aviolla Terza Damaliana<sup>3</sup>

<sup>1,2,3</sup>Jurusan Sains Data, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur

<sup>1</sup>22083010061@student.upnjatim.ac.id, <sup>2</sup>arman.prasetya.sada@upnjatim.ac.id\*,

<sup>3</sup>aviolla.terza.sada@upnjatim.ac.id\*

### Abstract

*Forest fires in South Kalimantan showed a sharp increase in occurrence during 2023, coinciding with dry conditions associated with El Niño. Although the number of fire events was high, the severity of fires varied across locations. This study analyzes environmental factors influencing forest fire severity using Geographically Weighted Regression (GWR) to account for spatial variation. Fire severity was measured using the Differenced Normalized Burn Ratio derived from satellite imagery. Environmental predictors included air temperature, total precipitation, elevation, and vegetation moisture, obtained from ERA5 Land reanalysis data, SRTM, and Landsat imagery. Results indicate that fire severity exhibits positive spatial autocorrelation, suggesting spatially varying relationships between environmental factors and burn severity. Compared with a global Ordinary Least Squares model, the GWR model provided improved explanatory power and reduced spatial autocorrelation in residuals. Total precipitation and vegetation moisture showed the most consistent spatial influence on fire severity, while temperature and elevation had weaker and more localized effects. These findings suggest that spatial modeling is useful for understanding variations in forest fire severity and for supporting location specific fire management strategies.*

**Keywords:** forest fire, burn severity, Geographically Weighted Regression, South Kalimantan

### Abstrak

Kebakaran hutan di Kalimantan Selatan menunjukkan peningkatan tajam dalam frekuensi kejadian pada tahun 2023, bertepatan dengan kondisi kering yang terkait dengan fenomena El Niño. Meskipun jumlah kejadian kebakaran tinggi, tingkat keparahan kebakaran bervariasi di berbagai lokasi. Penelitian ini menganalisis faktor lingkungan yang mempengaruhi tingkat keparahan kebakaran hutan menggunakan *Geographically Weighted Regression (GWR)* untuk memodelkan variasi spasial. Keparahan kebakaran diukur menggunakan *Differenced Normalized Burn Ratio* yang diperoleh dari citra satelit. Prediktor lingkungan meliputi suhu udara, curah hujan total, ketinggian, dan kelembaban vegetasi, yang diperoleh dari data reanalisis ERA5 Land, SRTM, dan citra Landsat. Hasil menunjukkan bahwa keparahan kebakaran menunjukkan korelasi spasial positif, menunjukkan hubungan yang bervariasi secara spasial antara faktor lingkungan dan keparahan kebakaran. Dibandingkan dengan model *Ordinary Least Squares* global, model GWR memberikan daya penjas yang lebih baik dan mengurangi autokorelasi spasial pada residual. Curah hujan total dan kelembaban vegetasi menunjukkan pengaruh spasial yang paling konsisten terhadap tingkat keparahan kebakaran, sementara suhu dan ketinggian memiliki efek yang lebih lemah dan lebih lokal. Temuan ini menunjukkan bahwa pemodelan spasial berguna untuk memahami variasi tingkat keparahan kebakaran hutan dan untuk mendukung strategi pengelolaan kebakaran yang spesifik lokasi.

**Kata kunci:** kebakaran hutan, keparahan kebakaran, Geographically Weighted Regression, Kalimantan Selatan

## Pendahuluan

Pada tahun 2023, Provinsi Kalimantan Selatan mengalami kebakaran hutan yang paling parah di Indonesia. Provinsi ini mengalami kebakaran dengan luas 1.875 kilometer persegi [1]. Luas kebakaran tersebut meningkat signifikan dibandingkan dengan luas kebakaran yang terjadi pada tahun 2022 dengan luas 4,29 kilometer persegi [1]. Peningkatan signifikan ini terjadi bersamaan dengan kejadian El Niño di Indonesia [2], yang merupakan suatu fenomena yang mengubah pola curah hujan di kawasan Asia Tenggara [3]. Dengan berkurangnya curah hujan, kelembapan tanah dan vegetasi akan berkurang, yang dapat meningkatkan kemungkinan terjadinya kebakaran. Hubungan antara El Niño dengan kejadian kebakaran pada penelitian [4] menunjukkan terjadi peningkatan luas kebakaran, dibandingkan dengan kejadian kebakaran saat tidak terjadi El Niño.

Beberapa upaya untuk menangani kebakaran hutan adalah dengan mempersiapkan mitigasi serta mencegah agar kejadian kebakaran tidak menimbulkan kerusakan yang parah. Pencegahan kebakaran yang parah menjadi penting, karena semakin parah kebakaran terjadi, waktu pulih lingkungan tersebut akan menjadi lebih lama [4]. Upaya pencegahan kebakaran yang parah, dapat dilakukan dengan mengetahui faktor-faktor pemengaruh yang terlibat dalam meningkatkan tingkat keparahan kebakaran. Berdasarkan meningkatnya kejadian kebakaran di Kalimantan Selatan dan pentingnya memahami tingkat keparahan kebakaran dalam konteks restorasi lingkungan, penelitian mengenai faktor-faktor yang memengaruhi kebakaran parah menjadi sangat penting. Hasil penelitian ini dapat digunakan untuk merancang strategi mitigasi yang efektif.

Berdasarkan penelitian, tingkat keparahan kebakaran ditentukan oleh berbagai faktor lingkungan, meliputi faktor cuaca, faktor topografi [6], serta kelembapan vegetasi [7]. Ketiga faktor tersebut berperan penting dalam menentukan keparahan kebakaran yang terjadi. Dengan mengetahui hubungan faktor-faktor tersebut, dapat dilakukan upaya-upaya untuk meminimalisir tingkat keparahan kebakaran.

Penelitian mengenai kebakaran hutan di Indonesia telah banyak dilakukan, tetapi penelitian khusus mengenai keparahan kebakaran hutan masih terbatas. Metode regresi global, seperti *Regularized Regression Model*, telah digunakan dalam penelitian [8]. Penelitian sebelumnya mengasumsikan terdapat hubungan spasial yang konstan antara faktor pemengaruh dan keparahan kebakaran. Namun, terdapat faktor spasial yang berbeda yang dapat mempengaruhi kebakaran hutan [9], yang tidak dapat dijelaskan dengan metode regresi global. Faktor spasial ini, seperti karakteristik tipe hutan, dapat menyebabkan perbedaan dalam hubungan antara variabel penyebab kebakaran pada berbagai tipe hutan.

Untuk mengatasi keterbatasan penelitian mengenai keparahan kebakaran di Kalimantan Selatan, penelitian ini menggunakan *Geographically Weighted Regression (GWR)*, sebuah metode analisis spasial yang dapat memodelkan variasi spasial antar lokasi. Metode ini merupakan perkembangan dari metode regresi linear, dimana model regresi linear akan menghasilkan satu persamaan. Dengan metode GWR, akan dilakukan pemodelan untuk setiap lokasi kejadian kebakaran, yang akan menghasilkan model yang khusus atau lokal untuk lokasi tersebut. Hal ini memungkinkan penelitian tentang bagaimana hubungan antara faktor pemengaruh dengan keparahan kebakaran hutan berbeda dari satu lokasi ke lokasi lainnya. Metode ini telah digunakan dalam penelitian sebelumnya [9], yang menunjukkan metode GWR memiliki akurasi yang lebih baik daripada model regresi global dalam menjelaskan variasi spasial.

Dalam penelitian ini, digunakan data dari berbagai sumber untuk menentukan tingkat keparahan kebakaran dan juga kondisi lingkungan. Sumber data untuk faktor cuaca berasal dari *ERA5-Land* [13], yang merupakan data cuaca harian seperti suhu, curah hujan, kelembapan relatif, dan kecepatan angin. Setelah itu, data kondisi vegetasi diperoleh dari citra satelit Landsat, yang menyediakan informasi spasial tentang tutupan lahan dan indeks vegetasi yang memengaruhi perilaku dan tingkat keparahan kebakaran.

Tujuan utama penelitian ini adalah untuk mengidentifikasi dan mengukur faktor-faktor yang memengaruhi keparahan kebakaran di Kalimantan Selatan pada tahun 2023, dengan fokus pada bagaimana hubungan-hubungan ini bervariasi secara spasial di seluruh provinsi. Tujuan lainnya yaitu untuk menentukan wilayah

mana yang sensitif terhadap variabel lingkungan tertentu, dan menghasilkan prediksi yang dapat digunakan untuk merumuskan strategi pengelolaan dan pencegahan kebakaran di tingkat lokal.

Penelitian ini bermanfaat dengan menambahkan bukti mengenai hubungan non-stasioneritas spasial dalam faktor-faktor yang memengaruhi tingkat keparahan kebakaran di Kalimantan Selatan. Lalu, penelitian ini juga menunjukkan pengaplikasian metode GWR dalam *domain* kebakaran hutan. Pada akhirnya, hasil penelitian ini diharapkan dapat bermanfaat untuk lembaga pemerintah, pengelola hutan, dan pembuat kebijakan dalam menerapkan kebijakan untuk mengurangi keparahan kebakaran, berdasarkan resiko faktor kebakaran.

## Metode Penelitian

### Area Penelitian

Penelitian ini berfokus pada Provinsi Kalimantan Selatan, yang terletak di bagian selatan-tenggara pulau Kalimantan. Provinsi Kalimantan memiliki dua musim, yaitu musim hujan pada bulan Oktober hingga Maret dan musim kemarau pada bulan April hingga September. Provinsi ini memiliki karakteristik tanah yang didominasi oleh tanah alluvial dan latosol [10], yang membuat area ini lebih rawan erosi.

### Data Keparahan Kebakaran Hutan

Data kejadian kebakaran diperoleh dari *Global Fire Atlas* [11], sebuah kumpulan data yang menyediakan kejadian kebakaran lahan yang terjadi di dunia. Data ini menyertakan lokasi kebakaran, area kebakaran, serta waktu mulai dan berakhirnya kebakaran.

Keparahan kebakaran diukur menggunakan metrik *Differenced Normalized Burn Ratio* (dNBR). dNBR adalah metrik yang telah banyak digunakan untuk mengukur dampak kebakaran berdasarkan citra satelit. Metrik ini menangkap perubahan vegetasi dan kondisi permukaan yang disebabkan oleh kebakaran [12]. Nilai dNBR dihitung untuk semua titik kejadian api selama periode penelitian. Nilai dNBR dihitung menggunakan rumus:

$$dNBR = NBR_{pre} - NBR_{post}$$

dimana,

- $NBR_{pre}$ : nilai *Normalized Burn Ratio* sebelum terjadi kebakaran
- $NBR_{post}$ : nilai *Normalized Burn Ratio* setelah terjadi kebakaran

dengan *Normalized Burn Ratio* dihitung menggunakan rumus:

$$NBR = \frac{(NIR - SWIR)}{(NIR + SWIR)}$$

dimana,

- $NIR$ : nilai reflektansi dari *near-infrared*
- $SWIR$ : nilai reflektansi dari *shortwave-infrared*

Selanjutnya, tiga faktor yang digunakan dalam penelitian ini, yaitu: faktor cuaca, topografi, dan kelembapan vegetasi. Data faktor cuaca yang digunakan dalam penelitian ini bersumber dari *ERA5-Land reanalysis* [13]. Sumber data ini menyediakan data keadaan cuaca atau iklim seluruh dunia. Berikut ini adalah variabel cuaca yang digunakan dalam penelitian ini: temperatur udara ( $^{\circ}\text{C}$ ), kelembapan udara (%), jumlah presipitasi (mm), kecepatan angin (m/s). Keempat variabel tersebut akan dikumpulkan untuk semua area kejadian kebakaran. Variabel-variabel tersebut dikumpulkan dengan mengambil rata-rata nilainya berdasarkan 90 hari sebelum terjadi kebakaran.

Faktor topografi meliputi variabel ketinggian tanah yang berasal dari dataset NASA Shuttle Radar Topography Mission (SRTM) [14]. Data ini berasal dari perhitungan ketinggian berdasarkan observasi satelit SRTM yang membentuk *Digital Elevation Model* (DEM). Data ketinggian dikumpulkan untuk semua area kejadian kebakaran, dengan satuan meter.

Faktor kelembapan vegetasi dihitung menggunakan *Normalized Differenced Moisture Index* (NDMI), yang merupakan indikator kandungan air pada kanopi tanaman atau vegetasi [15]. Indeks ini dipilih karena dapat merepresentasikan nilai kelembapan pada hutan sebelum kejadian kebakaran. Nilai NDMI dihitung berdasarkan pengamatan reflektansi oleh satelit Landsat dengan mengambil rata-rata nilai data, 90 hari sebelum terjadinya kebakaran. Agregasi rata-rata dilakukan karena ada bagian wilayah yang tertutup awan, yang menyebabkan gagal diambilnya data. Maka dari itu, digunakan rata-rata untuk mendapatkan nilai yang lebih representatif. NDMI dihitung menggunakan rumus:

$$NDMI = \frac{(NIR - SWIR)}{(NIR + SWIR)}$$

dimana,

- *NIR*: nilai reflektansi dari *near-infrared*
- *SWIR*: nilai reflektansi dari *shortwave-infrared*

Data yang telah dikumpulkan akan digabungkan, dan dihasilkan data yang dimana setiap baris merepresentasikan kejadian kebakaran, dengan nilai suhu, kelembapan udara, kecepatan angin, curah hujan, ketinggian tanah, serta nilai kelembapan vegetasi. Lalu, dilakukan tahap pra-pemrosesan, yang dimulai dengan melakukan normalisasi sistem koordinat yang digunakan. Pada awalnya data menggunakan sistem koordinat berbasis *latitude* dan *longitude* dalam bentuk derajat, kemudian diubah menjadi sistem koordinat *UTM Zone 50S*, yang merupakan sistem koordinat berbasis meter. Hal ini dilakukan untuk menjadikan jarak spasial dalam satuan meter. Selanjutnya dilakukan penanganan data yang hilang. Dalam proses ini, data dengan nilai yang kosong, akan dihapus dari dataset akhir. Hasil dari pra-pemrosesan data, tidak ditemukan data yang memiliki nilai yang kosong, dan sistem koordinat telah diubah menjadi *UTM Zone 50S*.

Sebelum melakukan pemodelan dengan *Geographically Weighted Regression* (GWR), multikolinearitas di antara variabel independen dievaluasi menggunakan *Variance Inflation Factor* (VIF). Jika ada variabel yang memiliki nilai VIF lebih dari 10, maka variabel tersebut akan dihapus. Ambang batas ini merupakan standar dalam pemodelan regresi dan khususnya penting dalam regresi spasial, di mana estimasi parameter lokal dapat sensitif terhadap prediktor yang berlebihan [16].

### Pemodelan dengan *Geographically Weighted Regression*

Metode *Geographically Weighted Regression* (GWR) adalah metode pemodelan yang dapat mempelajari pola spasial non-stasioner yang ada pada data. GWR memperluas model regresi linier OLS dengan memperhitungkan struktur spasial dan mengestimasi model terpisah serta estimasi parameter lokal untuk setiap lokasi geografis dalam data berdasarkan subset lokal dari data menggunakan pembobotan yang berbeda-beda [17]. Model GWR dirumuskan sebagai:

$$y_i = \beta_0(u_i, v_i) + \sum_{k=1}^p \beta_k(u_i, v_i)x_{ki} + \epsilon_i$$

dimana,

- $y_i$ : variabel dependen observasi ke- $i$
- $\beta$ : koefisien model regresi
- $x_{ki}$ : variabel independen ke- $k$  untuk observasi ke- $i$

- $(u_i, v_i)$ : koordinat observasi ke-i
- $\epsilon_i$ : galat ke-i

Pemodelan metode GWR dilakukan menggunakan metode *Weighted Least Square*, yaitu:

$$\widehat{\beta}(i) = (X'W(i)X)^{-1}X'W(i)y$$

dimana,

- $\widehat{\beta}(i)$ : koefisien regresi observasi ke-i
- $X$ : matriks variabel independen
- $y$ : matriks variabel dependen
- $W(i)$ : matriks diagonal dengan nilai  $[w_1(i), w_2(i), w_3(i), \dots, w_n(i)]$ , dengan  $0 \leq w_j(i) \leq 1$  ( $i, j = 1, 2, 3, \dots, n$ )

Matriks  $W(i)$  merupakan matriks diagonal yang berisi nilai pembobot spasial untuk lokasi ke-i. Bobot spasial ini ditentukan oleh jarak antara lokasi ke-i dengan lokasi lainnya. Semakin dekat lokasi dengan lokasi ke-i, semakin kuat pengaruhnya (bobot semakin besar), begitu juga sebaliknya [18]. Nilai bobot pada GWR dihitung menggunakan fungsi pembobotan, diantaranya: fungsi bisquare, fungsi gaussian, fungsi adaptif bisquare, dan fungsi adaptif gaussian.

Untuk mengetahui bahwa model GWR sesuai untuk memodelkan keparahan kebakaran, maka dilakukan perbandingan antara model GWR dengan model regresi global OLS. Perbandingan model dilakukan dengan melakukan uji kesesuaian menggunakan Uji  $F_1$ . Bentuk hipotesis uji  $F_1$  sebagai berikut:

$H_0$ : Tidak ada perbedaan yang signifikan antara OLS dan GWR.

$H_1$ : Ada perbedaan yang signifikan antara OLS dan GNNWR.

Dengan statistik uji yang dihitung menggunakan rumus:

$$F_1 = \frac{(RSS_G / \delta_1)}{(RSS_O / (n - p - 1))}$$

Keterangan:

- $RSS_G$  : *residual sum of squares* model GWR
- $RSS_O$  : *residual sum of squares* model OLS
- $\delta_1$  : derajat kebebasan model GWR
- $n$  : jumlah observasi
- $p$  : jumlah variabel independen

Kriteria pengujian tolak  $H_0$  jika nilai  $F_1 < F_{1-\alpha}(\frac{\delta_1^2}{\delta_2})$ .

Seperti pada pemodelan regresi linier, dalam pemodelan GWR juga dilakukan pengujian residual dan pengujian kesesuaian model. Residual model GWR harus memenuhi asumsi residual berdistribusi normal, bersifat homoskedastisitas (varians konstan), dan tidak terjadi autokorelasi secara spasial [19]. Dalam penelitian ini digunakan uji Shapiro-Wilk untuk menguji normalitas, uji Breusch-Pagan untuk menguji homoskedastisitas, dan *Moran's I* untuk menguji autokorelasi spasial. Setelah itu, untuk mengetahui akurasi model, dilakukan evaluasi model menggunakan metrik koefisien determinasi (*R-square*), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

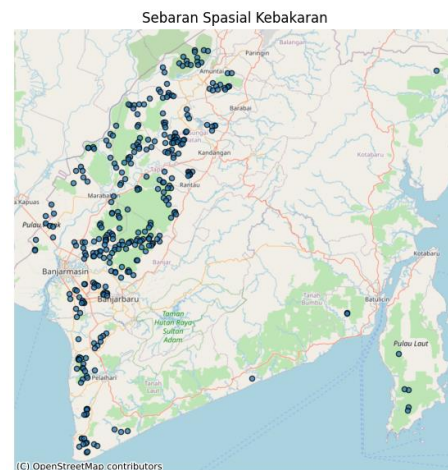
Pada akhir penelitian, dilakukan eksplorasi dan interpretasi hasil model GWR. Interpretasi dilakukan dengan melakukan visualisasi terhadap koefisien determinasi untuk semua lokasi kebakaran. Visualisasi dibentuk sebagai suatu peta. Selain itu, juga dibuat peta yang menunjukkan nilai koefisien setiap faktor-faktor pemengaruh keparahan kebakaran.

## Hasil dan Pembahasan

Hasil pengumpulan data didapatkan 406 dari 434 kejadian kebakaran hutan di Kalimantan Selatan yang terjadi pada 2023. Terdapat perbedaan jumlah kejadian, dikarenakan dilakukan penghapusan data untuk kebakaran yang terjadi di air dan pemukiman. Keparahan kebakaran hutan, dihitung menggunakan dNBR (*Differenced Normalized Burn Ratio*). Berdasarkan data yang dikumpulkan, distribusi nilai dNBR mulai dari -0,21 hingga 0.85 dengan rata-rata 0,332, dan standar deviasi 0,195. Hasil uji autokorelasi spasial pada variabel dNBR menghasilkan nilai *Moran's I* 0,3008 ( $p = 0,001$ ), yang menunjukkan adanya autokorelasi spasial positif. Kejadian kebakaran pada tahun 2023, menunjukkan kebakaran terjadi pada bulan Juli dan Oktober, dengan peningkatan signifikan pada September. Grafik kejadian kebakaran bulanan ditunjukkan pada Gambar 1. Tempat kejadian kebakaran terpusat pada bagian barat Kalimantan Selatan yang padat dengan wilayah hutan (Gambar 2).

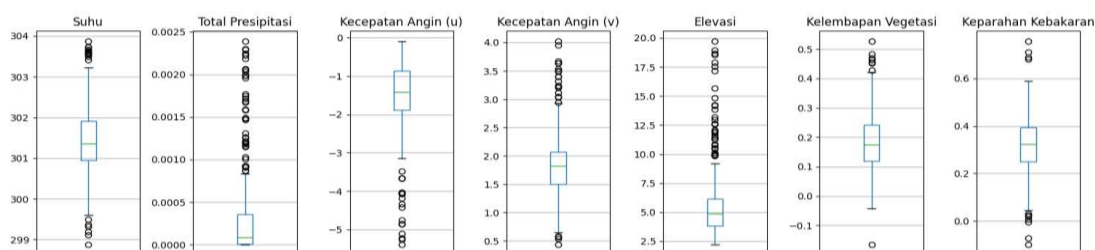


Gambar 1 Jumlah Kejadian Kebakaran Bulanan



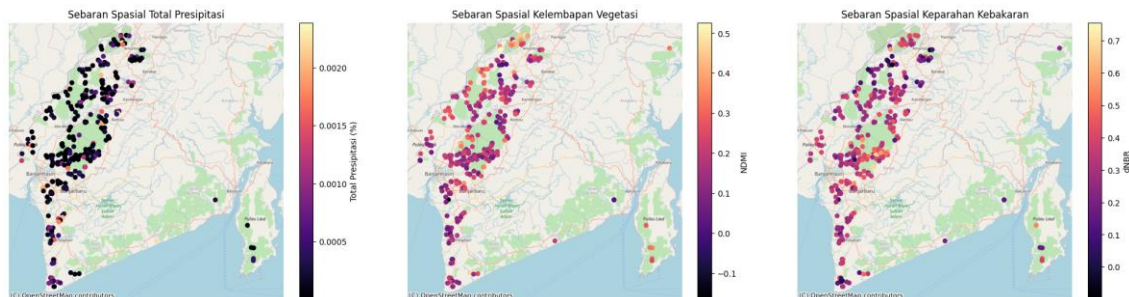
Gambar 2 Sebaran Kejadian Kebakaran Hutan

Hasil boxplot pada Gambar 3 menunjukkan bahwa suhu relatif stabil dengan variasi yang kecil. Total presipitasi memiliki distribusi yang condong ke kanan, dengan sebagian besar observasi mendekati nol dan kejadian hujan berintensitas tinggi yang bersifat tidak teratur. Komponen kecepatan angin menunjukkan perbedaan variabilitas, di mana komponen u memiliki sebaran yang lebih luas dan beberapa nilai ekstrem, sementara elevasi didominasi oleh nilai rendah dengan beberapa pencilan pada elevasi tinggi. Kelembapan vegetasi berada pada kisaran rendah hingga sedang, yang mencerminkan heterogenitas kondisi permukaan. Keparahan kebakaran juga menunjukkan distribusi condong ke kanan, dengan sebagian besar kejadian berada pada tingkat rendah hingga menengah dan sejumlah kecil kejadian dengan tingkat keparahan tinggi.



Gambar 3 Box Plot Data Kebakaran Hutan

Variasi spasial faktor pemengaruh total presipitasi dan kelembapan vegetasi ditunjukkan pada Gambar 4. Berdasarkan visualisasi tersebut, ditemukan bahwa pola distribusi spasial pada variabel total presipitasi sama rata untuk sebagian besar lokasi kejadian kebakaran. Sedangkan sebaran spasial kelembapan vegetasi dan keparahan kebakaran tidak menunjukkan pola spasial tertentu. Berdasarkan perbandingan antara faktor pemengaruh dan keparahan kebakaran, tidak ditemukan adanya pola yang secara langsung menghubungkan pengaruh faktor dengan tingkat keparahan kebakaran.



Gambar 4 Variasi Spasial Total Presipitasi dan Kelembapan Vegetasi

Sebelum dilakukan pemodelan, nilai *variance inflation factors* (VIF) dihitung untuk semua variabel independen, untuk mengetahui multikolinieritas antar variabel (Tabel 1). Ketika semua variabel digunakan, didapatkan bahwa terdapat multikolinieritas yang signifikan, yang ditunjukkan dengan nilai VIF lebih dari 10 [16]. Maka dari itu, dilakukan penghapusan variabel dengan nilai VIF yang tinggi. Pada akhirnya, variabel yang digunakan adalah: suhu, total presipitasi, elevasi tanah, dan kelembapan vegetasi.

Tabel 1 Hasil Tahap Multikolinieritas

Variabel	VIF Awal	VIF Akhir	Status
Suhu	34.701	6.026	Tetap
Total Presipitasi	11.427	8.180	Tetap
Kecepatan Angin (u)	23.656	-	Dihapus
Kecepatan Angin (v)	39.394	-	Dihapus
Elevasi Tanah	1.085	1.080	Tetap
Kelembapan Vegetasi	4,884	4,700	Tetap

Setelah itu, dilakukan pemodelan menggunakan *Ordinary Least Squares* (OLS) sebagai model dasar untuk memodelkan keparahan kebakaran. Koefisien model OLS ditunjukkan pada Tabel 2. Variabel kelembapan vegetasi menjadi variabel yang paling berpengaruh dalam model OLS. Elevasi tanah menunjukkan hubungan negatif yang signifikan dengan tingkat keparahan kebakaran hutan. Sementara variabel total presipitasi dan suhu tidak menunjukkan hubungan yang signifikan. Model OLS menghasilkan model yang dapat menjelaskan 15% dari variansi dengan metrik RMSE sebesar 0,1163. Pengujian dengan *Moran's I* menunjukkan autokorelasi spasial pada residual model OLS ( $I = 0,287, p = 0,001$ ), yang menunjukkan terdapat variansi spasial antara variabel independen dengan keparahan kebakaran.

Tabel 2 Koefisien Model OLS

Variabel	Koefisien	p-value
<i>Intercept</i>	11.3753	0,000
Suhu	-23.3619	0.070
Total Presipitasi	-0.0368	0.000
Elevasi Tanah	-0.0049	0.039
Kelembapan Vegetasi	0,5175	0.000

Hasil uji Moran's I pada residual model OLS menunjukkan adanya autokorelasi spasial, yang menunjukkan diperlukannya model yang dapat menangani variansi spasial. Maka selanjutnya dilakukan pemodelan dengan *Geographically Weighted Regression (GWR)*. Perhitungan bobot pada model GWR dilakukan menggunakan kernel adaptif *bi-square*, yang dilanjutkan dengan pemilihan *bandwidth* menggunakan *golden section search* dan metrik *Corrected Akaike Information Criterion (AICc)*. Hasil pemilihan bandwidth didapatkan nilai 65, yang mana setiap lokasi akan menggunakan 65 observasi sekitar. Hasil pemodelan GWR disajikan pada Tabel 3.

Tabel 3 Koefisien Model GWR

Variabel	Mean	STD	Min	Max
<i>Intercept</i>	9,514	9,403	-15,770	34,267
Suhu	-0,031	0,031	-0,113	0,053
Total Presipitasi	-9,999	37,728	-91,255	152,370
Elevasi Tanah	-0,007	0,017	-0,049	0,036
Kelembapan Vegetasi	0,429	0,394	-0,829	1,334

Hasil pemodelan GWR dapat menjelaskan rata-rata 61% variansi dalam keparahan kebakaran. Koefisien model GWR menunjukkan variasi spasial yang kuat pada hubungan antara faktor pemengaruh dengan tingkat keparahan kebakaran.

Koefisien variabel total presipitasi bernilai antara -91,255 hingga 152,370, dengan rata-rata -9,999 yang menunjukkan pengaruh total presipitasi yang kuat di seluruh lokasi kebakaran. Koefisien total presipitasi menunjukkan bahwa peningkatan curah hujan sebesar 10 mm dapat menurunkan nilai dNBR antara 0,10 hingga 0,90 pada sebagian besar wilayah, yang mencerminkan berkurangnya tingkat keparahan kebakaran akibat kondisi bahan bakar yang lebih lembap. Koefisien suhu dan elevasi tanah menunjukkan variasi spasial dan pengaruh yang lemah, dengan koefisien rata-rata mendekati nol. Koefisien kelembapan vegetasi yang cenderung bernilai negatif menunjukkan bahwa vegetasi dengan kandungan air yang lebih tinggi sebelum kejadian kebakaran cenderung mengalami tingkat keparahan yang lebih rendah. Hal ini konsisten dengan penelitian [20], di mana bahan bakar dengan kadar air tinggi membutuhkan energi lebih besar untuk terbakar secara intensif.

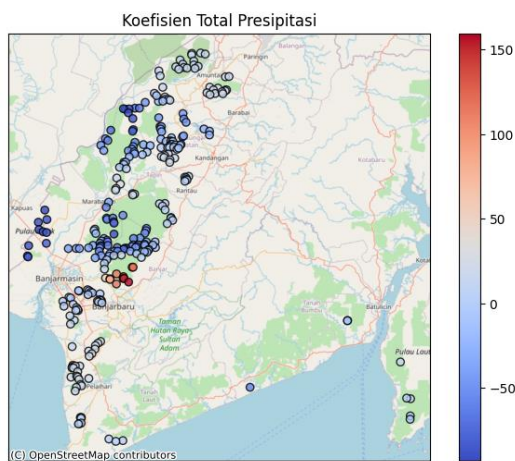
Model GWR menunjukkan nilai *R-square* yang beragam, mulai dari 9,87% hingga 76,21%. Dengan nilai *R-square* rata-rata 62,3%. Variasi nilai *R-square* ini menunjukkan bahwa kemampuan faktor-faktor pemengaruh dalam menjelaskan tingkat keparahan kebakaran berbeda antar lokasi, di mana beberapa wilayah menunjukkan kesesuaian model yang lebih baik, dengan nilai *R-square* tertinggi mencapai 76,21%. Secara keseluruhan, hasil *R-square* model GWR menunjukkan peningkatan kemampuan penjelasan dibandingkan dengan model OLS.

Selain nilai *R-square* yang lebih baik, hasil evaluasi model GWR juga menunjukkan akurasi yang lebih baik. Metrik *Root Mean Squared Error (RMSE)* berkurang dari 0,1163 pada model OLS menjadi 0,0785 pada model GWR. Metrik MAPE juga menunjukkan penurunan dari 76,53% pada model OLS menjadi 42,42% pada model GWR. Selanjutnya, autokorelasi spasial residual pada model GWR juga menunjukkan hasil yang lebih baik, dengan nilai *Moran's I* -0.008 ( $p = 0,437$ ), dibandingkan dengan residual model OLS 0,287 ( $p = 0,001$ ). Dengan *p-value* lebih dari 0,05 menunjukkan autokorelasi spasial sudah berkurang pada residual model GWR. Dengan itu, menunjukkan bahwa model GWR dapat menangkap pola spasial pada data keparahan kebakaran.

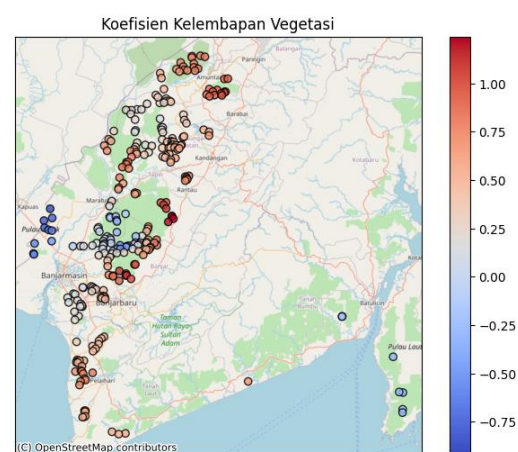
Untuk menunjukkan perbandingan model OLS dan GWR yang lebih definitif, dilakukan pengujian  $F_1$  untuk mengetahui kesesuaian model GWR. Hasil pengujian  $F_1$  menunjukkan nilai hitung  $F$  3,413 dengan *p-value* sebesar 0,000, yang menunjukkan bahwa model GWR memiliki performa prediksi yang lebih baik daripada model OLS. Selain itu, juga menunjukkan adanya non-stasioneritas spasial dalam hubungan antara faktor pemengaruh dengan tingkat keparahan kebakaran, artinya total presipitasi, suhu, ketinggian, dan kelembapan vegetasi memiliki pengaruh yang bervariasi tergantung pada lokasi terjadinya kebakaran.

Peta koefisien model GWR menunjukkan variasi spasial yang kuat pada pengaruh total presipitasi dan kelembapan vegetasi terhadap tingkat keparahan kebakaran. Peta koefisien total presipitasi pada Gambar 4 menunjukkan nilai negatif dan dominan di bagian barat Kalimantan Selatan mengindikasikan bahwa peningkatan curah hujan sebelum kejadian kebakaran berperan dalam menurunkan tingkat keparahan kebakaran melalui peningkatan kelembapan bahan bakar. Sebaliknya, koefisien presipitasi positif yang muncul secara lokal menunjukkan bahwa pada beberapa wilayah, terutama area yang telah mengalami modifikasi lahan, curah hujan tidak secara langsung menurunkan keparahan kebakaran.

Koefisien kelembapan vegetasi juga menunjukkan pola spasial yang beragam (Gambar 5). Nilai negatif yang terkonsentrasi di wilayah rawa gambut mencerminkan peran penting kandungan air vegetasi dalam menekan intensitas pembakaran, sementara nilai positif di wilayah lain mengindikasikan bahwa kelembapan vegetasi saja tidak cukup untuk membatasi keparahan kebakaran, terutama pada area dengan akumulasi bahan bakar yang tinggi. Temuan ini menegaskan bahwa pengaruh faktor lingkungan terhadap keparahan kebakaran bersifat non-stasioner dan sangat bergantung pada karakteristik ekosistem lokal.



Gambar 4 Sebaran Koefisien Total Presipitasi



Gambar 5 Sebaran Koefisien Kelembapan Vegetasi

## Kesimpulan

Penelitian ini menganalisis faktor faktor yang memengaruhi tingkat keparahan kebakaran hutan di Kalimantan Selatan pada tahun 2023 dengan menggunakan pendekatan *Geographically Weighted Regression*. Hasil analisis menunjukkan bahwa tingkat keparahan kebakaran memiliki pola spasial yang tidak seragam, sehingga pendekatan regresi global kurang mampu menjelaskan variasi yang terjadi antar lokasi. Model GWR menunjukkan kinerja yang lebih baik dibandingkan model OLS, ditunjukkan oleh peningkatan nilai koefisien determinasi, penurunan nilai kesalahan prediksi, serta berkurangnya autokorelasi spasial pada residual. Analisis koefisien GWR menunjukkan variabel total presipitasi dan kelembapan vegetasi merupakan faktor yang paling konsisten memengaruhi keparahan kebakaran, dengan pengaruh yang bervariasi secara spasial. Curah hujan dan kandungan air vegetasi yang lebih tinggi sebelum kejadian kebakaran cenderung berkaitan dengan tingkat keparahan yang lebih rendah. Sementara itu, pengaruh suhu dan elevasi relatif lemah dan berbeda antar wilayah. Temuan ini menunjukkan bahwa hubungan antara faktor lingkungan dan keparahan kebakaran bersifat non stasioner dan bergantung pada kondisi lokal. Oleh karena itu, strategi mitigasi dan pengelolaan kebakaran hutan perlu mempertimbangkan karakteristik spasial wilayah, khususnya terkait kondisi curah hujan dan kelembapan vegetasi, agar upaya pengurangan dampak kebakaran dapat dilakukan dengan tepat sasaran.

## Daftar Rujukan

- [1] Direktorat Pengendalian Kebakaran Hutan, Kementerian Kehutanan, 'Indikasi Luas Kebakaran Hutan dan Lahan (Ha) per Provinsi di Indonesia', 2026. [Online]. Available: <https://sipongi.gakkum.kehutan.go.id/indikasi-luas-kebakaran>.
- [2] I. T. N. H. Ullum, A. Fitria, and W. Widodo, 'Variasi Hasil Analisis Data Hasil El Nino-Southern Oscillation (ENSO) terhadap Iklim Global', *Jurnal Sains Natural*, vol. 2, no. 2, pp. 40–47, 2024.
- [3] N. S. Gunawan, M. Izzudin, A. Atiawati, C. Latifa, F. Febrianti, and D. Desmawan, 'Dampak El Nino Terhadap Produktivitas Pertanian Analisis Sistematis Ketahanan Pangan di Wilayah Tropis', *Ekonomi Bisnis Manajemen dan Akuntansi (EBMA)*, vol. 5, no. 2, pp. 28–35, 2024.
- [4] C. Burton, R. A. Betts, C. D. Jones, T. R. Feldpausch, M. Cardoso, and L. O. Anderson, 'El Niño Driven Changes in Global Fire 2015/16', *Frontiers in Earth Science*, vol. 8, June 2020.
- [5] S. Zahabnazouri, P. Belmont, S. David, P. E. Wigand, M. Elia, and D. Capolongo, 'Detecting Burn Severity and Vegetation Recovery After Fire Using dNBR and dNDVI Indices: Insight from the Bosco Difesa Grande, Gravina in Southern Italy', *Sensors*, vol. 25, no. 10, p. 3097, May 2025.
- [6] G. K. Dillon, Z. A. Holden, P. Morgan, M. A. Crimmins, E. K. Heyerdahl, and C. H. Luce, 'Both topography and climate affected forest and woodland burn severity in two regions of the western US, 1984 to 2006', *Ecosphere*, vol. 2, no. 12, p. art130, Dec. 2011.
- [7] P. G. Sikkink and R. E. Keane, *Predicting fire severity using surface fuels and moisture*. 2012.
- [8] S. Nurdianti, I. W. Mangku, I. F. Hawari, and M. K. Najib, 'PREDICTING FOREST FIRE HOTSPOTS IN KALIMANTAN USING BEST SUBSET VARIABLE SELECTION, REGULARIZED REGRESSION MODEL, AND BAYESIAN MODEL AVERAGING', *Geographia Technica*, vol. 20, no. 2/2025, pp. 150–178, May 2025.
- [9] H.-J. Lee, E.-J. Kim, and S.-W. Lee, 'Examining Spatial Variation in the Effects of Japanese Red Pine (*Pinus densiflora*) on Burn Severity Using Geographically Weighted Regression', *Sustainability*, vol. 9, no. 5, p. 804, May 2017.
- [10] N. S. Daulay, N. Armita, and Others, 'KARAKTERISTIK TANAH DI KALIMANTAN DAN HUBUNGANNYA DENGAN PROSES GEOMORFOLOGI', *Journal Education, Sociology and Law*, vol. 1, no. 1, pp. 204–211, 2025.
- [11] N. Andela and M. W. Jones, 'Update of: The Global Fire Atlas of individual fire size, duration, speed and direction'. Zenodo, 2025.
- [12] A. Sukmono, F. Hadi, E. Widayanti, A. L. Nugraha, and N. Bashit, 'Identifying Burnt Areas in Forests and Land Fire Using Multitemporal Normalized Burn Ratio (NBR) Index on Sentinel-2 Satellite Imagery', *International Journal of Safety and Security Engineering*, vol. 13, no. 3, pp. 469–477, July 2023.
- [13] Copernicus Climate Change Service, 'ERA5-Land monthly averaged data from 1950 to present'. Copernicus Climate Change Service (C3S) Climate Data Store (CDS), 2019.
- [14] A. Jarvis, H. I. Reuter, A. Nelson, and E. Guevara, 'Hole-filled SRTM for the Globe Version 4'. 2008.
- [15] P. V. Lykhovyd and V. O. Sharii, 'Normalised difference moisture index in water stress assessment of maize crops', *Agronomy*, vol. 7, no. 1, pp. 21–26, May 2024.
- [16] Z. Huisheng et al., 'Exploring groundwater potential: Combining GIS techniques with OLS, GWR, and exploratory regression', *Journal of Hydrology: Regional Studies*, vol. 61, p. 102564, Oct. 2025.
- [17] M. A. Senyel Kurkuoglu, 'Analysis of the energy justice in natural gas distribution with Multiscale Geographically Weighted Regression (MGWR)', *Energy Reports*, vol. 9, pp. 325–337, Dec. 2023.
- [18] M. Marsono, 'Faktor-Faktor yang Mempengaruhi Deforestasi Indonesia dengan Menggunakan Geographically Weighted Regression', *Reliability: Journal of Industrial Statistics*, vol. 1, no. 1, pp. 33–44, 2025.
- [19] A. Comber et al., 'A Route Map for Successful Applications of Geographically Weighted Regression', *Geographical Analysis*, vol. 55, no. 1, pp. 155–178, Jan. 2022.

[20] T. M. Ellis, D. M. Bowman, P. Jain, M. D. Flannigan, and G. J. Williamson, 'Global increase in wildfire risk due to climate-driven declines in fuel moisture', *Global change biology*, vol. 28, no. 4, pp. 1544–1559, 2022.