



Penerapan *Geographically and Temporally Weighted Regression* (GTWR) dalam Menganalisis Tingkat Pengangguran Terbuka di Indonesia

Arya Praditya¹, Prizka Rismawati Arum², Alwan Fadlurohman³

^{1, 2}Program Studi Statistika, Universitas Muhammadiyah Semarang

¹aryapraditya389@gmail.com

²prizka.rismawati@gmail.com

³Program Studi Sains Data, Universitas Muhammadiyah Semarang

³alwanr21@gmail.com

Corresponding author email: aryapraditya389@gmail.com

Abstract: The Open Unemployment Rate (OUR) is a key indicator for measuring labor market absorption and reflects the employment condition of a region. A high OUR in Indonesia indicates an imbalance between labor supply and demand, which may impact economic growth and societal welfare. This study aims to analyze the influence of social, economic, and environmental factors on OUR across 34 provinces in Indonesia during the 2019–2023 period using a spatio-temporal approach. The Geographically Weighted Regression (GWR) method is employed to capture spatial variation, while the Geographically and Temporally Weighted Regression (GTWR) method is applied to simultaneously account for spatial and temporal variation. The best model is selected based on the lowest Akaike Information Criterion (AIC), the highest R^2 , and the lowest Cross-Validation (CV) value. The GTWR model with an adaptive tricube kernel weighting shows the best performance with an AIC of 196.8463, R^2 of 0.9776, and a MAPE of 3.1626. These results indicate that the GTWR model provides more accurate and context-sensitive estimates, making it a valuable tool for policymakers in formulating more effective and region-specific strategies to reduce unemployment.

Keywords: GTWR, open unemployment rate, spatial-temporal, unemployment, weighted regression

Abstrak: Tingkat Pengangguran Terbuka (TPT) merupakan indikator penting untuk mengukur kondisi ketenagakerjaan, mencerminkan ketidakseimbangan antara penawaran dan permintaan tenaga kerja. Tingginya TPT di Indonesia berdampak pada pertumbuhan ekonomi dan kesejahteraan masyarakat. Penelitian ini bertujuan untuk menganalisis pengaruh faktor sosial, ekonomi, dan lingkungan terhadap TPT di 34 provinsi di Indonesia selama periode 2019–2023 menggunakan pendekatan spasial-temporal. Metode *Geographically Weighted Regression* (GWR) digunakan untuk menangkap variasi spasial, sedangkan *Geographically and Temporally Weighted Regression* (GTWR) diterapkan untuk mempertimbangkan variasi spasial dan temporal secara bersamaan. Pemilihan model terbaik didasarkan pada nilai *Akaike Information Criterion* (AIC) terkecil, R^2 terbesar, dan *Cross-Validation* (CV) terkecil. GTWR dengan pembobot *adaptive tricube* kernel memberikan performa terbaik dengan AIC sebesar 196,8463, R^2 sebesar 0,9776, dan MAPE sebesar 3,1626. Hasil ini menunjukkan bahwa GTWR mampu memberikan estimasi yang lebih akurat dan kontekstual dibandingkan GWR, serta relevan untuk mendukung perumusan kebijakan pengurangan pengangguran berbasis kondisi wilayah secara spesifik.

Kata kunci: GTWR, pengangguran, regresi berbobot, spasial-temporal, tingkat pengangguran terbuka

I. PENDAHULUAN

Pengangguran adalah kondisi di mana individu berusia 15 tahun ke atas tidak bekerja dan sedang mencari pekerjaan, menyiapkan usaha, atau menyerah karena tidak ada peluang kerja. Indikator utama untuk mengukur kondisi ini adalah Tingkat Pengangguran Terbuka (TPT), yang mencerminkan ketidakseimbangan antara penawaran dan permintaan tenaga kerja. Tingginya TPT tidak hanya berdampak pada aspek ekonomi, seperti hilangnya potensi produksi nasional, tetapi juga menimbulkan masalah sosial, seperti penurunan pendapatan dan meningkatnya ketidakstabilan sosial. Dampak psikologis dan sosial pengangguran sering kali sulit diukur secara kuantitatif [1].

Indonesia sebagai negara dengan jumlah penduduk terbesar di Asia Tenggara memiliki potensi ekonomi yang besar, namun menghadapi tantangan serius terkait tingginya TPT. Pada tahun 2020, TPT mencapai 7,07% dan mengalami penurunan bertahap hingga 5,32% pada tahun 2023. Meskipun terjadi



penurunan secara nasional, disparitas antarprovinsi masih signifikan, yang mencerminkan perbedaan kondisi ketenagakerjaan berdasarkan faktor ekonomi, industri, kebijakan tenaga kerja, dan tingkat urbanisasi [2], [3].

Berbagai penelitian menunjukkan bahwa pengangguran dipengaruhi oleh faktor-faktor seperti pertumbuhan ekonomi, Indeks Pembangunan Manusia (IPM), upah minimum, pengeluaran pemerintah, dan Produk Domestik Regional Bruto (PDRB) [4], [5]. Namun, metode analisis yang digunakan selama ini cenderung berbasis regresi linier klasik atau data panel yang mengasumsikan parameter konstan antarwilayah. Hal ini mengabaikan heterogenitas spasial yang penting untuk memahami variasi lokal pengaruh variabel-variabel tersebut.

Untuk mengatasi keterbatasan tersebut, pendekatan spasial seperti *Geographically Weighted Regression* (GWR) telah digunakan untuk menangkap variasi pengaruh lokal. Namun, GWR belum mempertimbangkan dimensi temporal yang juga berperan dalam dinamika pengangguran. Oleh karena itu, metode *Geographically and Temporally Weighted Regression* (GTWR), yang memperhitungkan variasi spasial dan temporal, dipilih untuk analisis ini guna menghasilkan estimasi yang lebih akurat dan relevan [6], [7].

Pembobot dalam GTWR berperan penting dalam merepresentasikan kedekatan spasial dan temporal antara data pengamatan, di mana fungsi kernel seperti *Fixed* dan *Adaptive Kernel* digunakan untuk menghitung bobot pembobotan berdasarkan jarak dan kepadatan data [8]. Dengan pendekatan ini, diharapkan hasil analisis dapat memberikan wawasan lebih mendalam mengenai faktor-faktor yang mempengaruhi pengangguran di tingkat provinsi dan periode waktu tertentu, sehingga dapat mendukung kebijakan ketenagakerjaan yang lebih efektif dan adaptif.

II. METODE PENELITIAN

2.1. Sumber Data

Penelitian ini menggunakan data sekunder dari situs resmi Badan Pusat Statistik (BPS) yang mencakup 34 provinsi di Indonesia selama periode 2019–2023, guna memberikan gambaran menyeluruh tentang kondisi dan perkembangan wilayah dalam rentang waktu tersebut.

2.2. Tahapan Penelitian

Langkah-langkah analisis *Geographically and Temporally Weighted Regression* (GTWR) meliputi tahapan-tahapan berikut [6], [9]:

1. Input data variabel dependen dan independen serta standarisasi;
2. Analisis regresi linier berganda;
3. Uji *Breusch-Pagan* untuk mengidentifikasi heterogenitas spasial;
4. Analisis GWR melalui perhitungan jarak *Euclidean*, pemilihan *bandwidth* optimal *Fixed* dan *Adaptive Kernel*, dan estimasi parameter menggunakan WLS;
5. Analisis heterogenitas temporal dengan boxplot;
6. Analisis GTWR melalui estimasi parameter spasial-temporal (τ , μ , λ), *bandwidth* spasial-temporal, dan estimasi model;
7. Pengujian model secara parsial dan simultan dengan uji F dan t;
8. Perbandingan model GWR dan GTWR menggunakan AIC, R^2 , dan MAPE;
9. Visualisasi hasil melalui peta persebaran faktor-faktor yang memengaruhi pengangguran dan interpretasi model terbaik.



2.3. Analisis Regresi

Regresi merupakan metode analisis yang dimanfaatkan untuk memahami seberapa besar pengaruh variabel independen terhadap variabel dependen, sekaligus memperkirakan nilai variabel dependen berdasarkan data yang telah dikumpulkan. Tujuan utama regresi adalah meminimalkan selisih antara nilai aktual dan nilai prediksi (residual). Salah satu metode yang umum digunakan adalah *Ordinary Least Squares* (OLS), yang dikenal sebagai metode klasik. OLS bekerja dengan meminimalkan jumlah kuadrat residual untuk menghasilkan estimasi parameter yang terbaik. Metode ini memberikan hasil optimal apabila asumsi *Best Linear Unbiased Estimator* (BLUE) terpenuhi [10]. Adapun penaksiran parameternya adalah sebagai berikut:

$$\hat{\beta} = (X^T X)^{-1} X^T Y \quad (1)$$

2.4. Geographically and Temporally Weighted Regression (GTWR)

Geographically and Temporally Weighted Regression (GTWR) adalah model yang memperlakukan lokasi spatio-temporal setiap unit observasi sebagai parameter regresi, dengan nilai-nilai parameter bergantung pada posisi geografis dan unit temporal tersebut. Pendekatan ini memungkinkan model untuk menangkap karakteristik lokal dari hubungan regresi di setiap lokasi dan waktu tertentu [11]. Berikut adalah rumus dasar dari model GTWR

$$Y_i = \beta_0(u_i, v_i, t_i) + \sum_{k=1}^p \beta_k(u_i, v_i, t_i) x_{ik} + \varepsilon_i \quad i = 1, 2, \dots, n \quad (2)$$

Model ini mengestimasi intersep dan koefisien regresi pada setiap titik lokasi dan waktu menggunakan metode *Weighted Least Square* (WLS), dengan bobot berdasarkan kedekatan spasial dan temporal antar observasi semakin dekat jaraknya, semakin besar pengaruhnya [11]. Bobot ini bergantung pada fungsi peluruhan jarak w_{ij} , yang memperhitungkan kedekatan dalam ruang dan waktu [12]. Matriks kedekatan spasial-temporal dibentuk dari kombinasi fungsi jarak spasial (d^S) dan jarak temporal (d^T), sehingga menghasilkan ukuran kedekatan gabungan antar unit observasi dalam dimensi ruang dan waktu.

$$(d^{ST})^2 = \lambda \{(u_i - u_j)^2 + (v_i - v_j)^2\} + \mu (t_i - t_j)^2 \quad (3)$$

Jika τ disimbolkan sebagai parameter rasio dari μ/λ dengan $\lambda \neq 0$ maka akan didapatkan persamaan:

$$\frac{(d_{ij}^{ST})^2}{\lambda} = (u_i - u_j)^2 + (v_i - v_j)^2 + \tau (t_i - t_j)^2 \quad (4)$$

Parameter τ berfungsi untuk mengatur pengaruh jarak temporal dalam hubungannya dengan jarak spasial. Parameter ini diperoleh berdasarkan R^2 terbesar berdasarkan nilai τ [12].

2.5. Pemilihan Model Terbaik

Perbandingan model dilakukan untuk mengidentifikasi model yang paling cocok dalam suatu analisis data. Terdapat berbagai pendekatan yang diterapkan untuk memilih model yang paling optimal antara lain:

1. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan ukuran rata-rata kesalahan persentase absolut. Dalam perhitungan MAPE, baik nilai positif maupun negatif dari kesalahan tidak diperhitungkan. Nilai MAPE yang semakin kecil menunjukkan bahwa tingkat kesalahan yang dihasilkan oleh model juga semakin berkurang [13].

$$MAPE = \frac{1}{n} \sum \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

**2. Akaike Information Criterion (AIC)**

Akaike Information Criterion (AIC) merupakan salah satu pendekatan yang umum digunakan dalam pemilihan model terbaik, dengan mempertimbangkan keseimbangan antara tingkat kompleksitas model dan tingkat kecocokan terhadap data. AIC memberikan penalti terhadap jumlah parameter yang digunakan, sehingga mencegah model menjadi terlalu kompleks. Semakin kecil nilai AIC, maka model dianggap semakin efisien dalam menjelaskan data tanpa *overfitting* dengan k menyatakan jumlah parameter dalam model dan L merupakan nilai maksimum dari fungsi likelihood [8].

$$AIC = 2n\log_e(\hat{\sigma}) + n\log_e(2\pi) + n\left\{\frac{n+tr(S)}{n-2-tr(S)}\right\} \quad (6)$$

3. Koefisien Determinasi (R^2)

Koefisien determinasi (R^2) merupakan indikator statistik yang menggambarkan proporsi variasi variabel dependen yang dapat dijelaskan oleh model regresi. Nilai R^2 berada dalam rentang 0 sampai 1; semakin mendekati 1, semakin baik model dalam memprediksi, sedangkan nilai yang mendekati 0 menandakan bahwa model kurang mampu menjelaskan variasi data. R^2 dihitung dengan membandingkan total kuadrat dengan kuadrat sisa yang tidak dapat dijelaskan oleh model [14].

$$R^2(u, v, t) = \frac{JKR_w \sum_j^p w_{ij}(y_j - \hat{y}_j)^2}{JKT_w \sum_{j \neq 1}^p w_{ij}(y_j - \bar{y})^2} \quad (7)$$

III. HASIL DAN PEMBAHASAN**3.1. Analisis Regresi**

Analisis regresi merupakan metode analisis yang dimanfaatkan untuk memahami seberapa besar pengaruh variabel bebas terhadap variabel terikat, sekaligus memperkirakan nilai variabel terikat berdasarkan data yang telah dikumpulkan. Hubungan ini dituangkan dalam bentuk model matematis, yang dalam kasus regresi linear dituliskan model regresinya sebagai berikut:

$$\hat{Y} = 0,0000 + 0,4616X_1 - 0,1965X_2 + 0,5735X_3 - 0,0334X_4 - 0,0917X_5$$

Selanjutnya, dilakukan pengujian signifikansi secara parsial untuk masing-masing variabel independen. Hasil dari pengujian ini disajikan pada Tabel 1.

Tabel 1. Pengujian Secara Parsial


Variabel	t_{hitung}	$p-value$	Kesimpulan
PDRB (X_1)	6,4980	0,0000	Signifikan
IPM (X_2)	-2,0749	0,0395	Signifikan
RLS (X_3)	6,1527	0,0000	Signifikan
UMP (X_4)	-0,5083	0,6118	Tidak Signifikan
Gini Rasio (X_5)	-1,4072	0,1612	Tidak Signifikan



3.2. Analisis Heterogenitas Spasial dan Temporal

Uji heterogenitas spasial dilakukan untuk mengetahui apakah terdapat perbedaan variansi antar wilayah dalam model. Pengujian ini menggunakan uji *Breusch-Pagan* dengan hipotesis nol (H_0) bahwa tidak terdapat heterogenitas spasial, dan hipotesis alternatif (H_1) bahwa terdapat heterogenitas spasial. Dengan menggunakan tingkat signifikansi 0,05, diperoleh nilai uji *Breusch-Pagan* sebesar 12,5650 dan *p-value* sebesar 0,0278. Karena *p-value* < 0,05, maka H_0 ditolak, sehingga dapat disimpulkan bahwa terdapat indikasi adanya heterogenitas spasial dalam model.

Analisis keragaman temporal bertujuan untuk mengidentifikasi adanya perubahan karakteristik data dari tahun ke tahun. Homogenitas temporal menunjukkan konsistensi nilai antar tahun, sedangkan heterogenitas temporal mengindikasikan adanya perbedaan karakteristik pada setiap periode. Uji ini penting dalam penerapan metode GTWR, dan dalam penelitian ini dianalisis melalui visualisasi boxplot.



Gambar 1. Boxplot Heterogenitas Temporal

Boxplot TPT Indonesia 2019–2023 menunjukkan heterogenitas temporal yang signifikan. Tahun 2019 relatif homogen dengan IQR sempit dan median rendah. Selama 2020–2021, variasi meningkat, median naik, dan muncul *outlier*. Pada 2022–2023, distribusi kembali lebih stabil dengan IQR menyempit dan *outlier* berkurang. Hasil ini menegaskan bahwa data TPT tidak homogen sepanjang waktu, sehingga metode GTWR tepat untuk menangkap dinamika spasial-temporal pengangguran.

3.3. Pembobot Kernel

Langkah awal dalam pemodelan spasial adalah menghitung jarak *Euclidean* antar lokasi, yang selanjutnya digunakan untuk menentukan bobot kernel yang sesuai dengan data pengamatan. Pemilihan kernel optimal dilakukan dengan mempertimbangkan beberapa kriteria evaluasi model, seperti nilai AIC, koefisien determinasi (*R-squared*), dan *Mean Absolute Percentage Error* (MAPE).

Tabel 2. Perbandingan Pembobot Kernel

Pembobot	Bandwidth	CV	AIC	R ²
Fixed Gaussian	3,704	71,263	293,060	0,724
Fixed Bisquare	11,941	77,809	326,167	0,653



Pembobot	Bandwidth	CV	AIC	R ²
<i>Fixed Tricube</i>	12,271	80,757	334,555	0,633
<i>Adaptive Gaussian</i>	21	79,440	333,612	0,624
<i>Adaptive Bisquare</i>	32	54,258	209,828	0,850
<i>Adaptive Tricube</i>	32	53,727	209,641	0,850

Berdasarkan kriteria evaluasi yang digunakan, diperoleh bahwa pembobot kernel yang optimal adalah *adaptive tricube*, karena menghasilkan nilai *Cross Validation* (CV) dan AIC terkecil serta nilai *R-squared* terbesar dibandingkan opsi lainnya.

3.4. Geographically Weighted Regression (GWR)

Model Geographically Weighted Regression (GWR) merupakan perluasan dari regresi linier klasik, di mana estimasi parameter dilakukan secara lokal pada masing-masing titik observasi. Oleh karena itu, setiap lokasi dapat memiliki nilai parameter yang berbeda, tergantung pada karakteristik spasial di sekitarnya [8]. Dalam melakukan estimasi model GWR, langkah-langkah yang dilakukan meliputi perhitungan jarak *Euclidean* antar lokasi sebagai dasar kedekatan spasial, pemilihan bobot optimal menggunakan metode *Cross-Validation*, AIC, dan MAPE untuk menentukan *bandwidth* terbaik yang didapatkan *bandwidth* terbaik adalah *adaptive tricube*, serta pembentukan matriks pembobot spasial yang digunakan dalam proses estimasi parameter model. Berdasarkan hasil analisis didapatkan kriteria pemilihan model menggunakan R² sebesar 0,8504, AIC sebesar 352,2341, dan MAPE sebesar 10,6958. Namun, model GWR belum mempertimbangkan dimensi waktu sehingga seluruh periode diasumsikan memiliki pola yang sama. Oleh karena itu, untuk menangkap variasi spasial sekaligus temporal, analisis dilanjutkan menggunakan model GTWR.

3.5. Geographically and Temporally Weighted Regression (GTWR)

Geographically and Temporally Weighted Regression (GTWR) adalah model yang memperlakukan lokasi spatio-temporal setiap unit observasi sebagai parameter regresi, dengan nilai-nilai parameter bergantung pada posisi geografis dan unit temporal tersebut. Pendekatan ini memungkinkan model untuk menangkap karakteristik lokal dari hubungan regresi di setiap lokasi dan waktu tertentu [11]. Dalam *Geographically and Temporally Weighted Regression* (GTWR) terdapat dua asumsi utama yang harus dipenuhi, yakni adanya heterogenitas secara spasial maupun temporal. Dalam poin sebelumnya sudah terbukti data pengamatan memenuhi kedua asumsi tersebut maka analisis dapat dilanjutkan.


Selanjutnya, dilakukan perhitungan jarak spasial-temporal, *bandwidth adaptive tricube*, serta matriks pembobot spasial-temporal melalui proses iterasi parameter *miu* dan *lambda* sebanyak 300 kali untuk memperoleh hasil yang optimal. Hasil iterasi menunjukkan bahwa kombinasi nilai *miu* sebesar 5,3100 dan *lambda* sebesar 3,5400 memberikan nilai *R-squared* maksimum sebesar 0,8789. Tahap selanjutnya melibatkan perhitungan matriks pembobot untuk melakukan pendugaan atau estimasi parameter model GTWR dalam memodelkan Tingkat Pengangguran Terbuka (TPT) di Indonesia. *Bandwidth* spasial-temporal dengan fungsi *adaptive tricube* menghasilkan nilai yang bervariasi pada tiap lokasi, mencerminkan heterogenitas spasial dan temporal dalam data. Nilai *bandwidth* lengkap disajikan pada tabel berikut:




Tabel 3. *Bandwidth* Spasial-Temporal

Provinsi	<i>Bandwidth</i>	Provinsi	<i>Bandwidth</i>
ACEH	19,0412	NUSA TENGGARA BARAT	18,6444
SUMATERA UTARA	13,0270	NUSA TENGGARA TIMUR	17,7067
SUMATERA BARAT	11,1745	KALIMANTAN BARAT	9,7431
RIAU	9,2376	KALIMANTAN TENGAH	11,9628
JAMBI	6,8764	KALIMANTAN SELATAN	13,4147
SUMATERA SELATAN	7,7439	KALIMANTAN TIMUR	10,3632
BENGKULU	8,6818	KALIMANTAN UTARA	10,5539
LAMPUNG	9,7431	SULAWESI UTARA	11,0557
KEP. BANGKA BELITUNG	12,3536	SULAWESI TENGAH	10,5539
KEP. RIAU	13,9232	SULAWESI SELATAN	10,3632
DKI JAKARTA	9,7506	SULAWESI TENGGARA	12,7785
JAWA BARAT	17,9237	GORONTALO	9,8211
JAWA TENGAH	10,1541	SULAWESI BARAT	11,0557
DI YOGYAKARTA	11,3195	MALUKU	19,1541
JAWA TIMUR	11,8100	MALUKU UTARA	13,2368
BANTEN	8,6818	PAPUA BARAT	21,3606
BALI	12,9352	PAPUA	38,0459


Selanjutnya, dilakukan perhitungan matriks pembobot spasial-temporal yang digunakan dalam proses estimasi parameter model. Hasil estimasi parameter dari pemodelan Tingkat Pengangguran Terbuka (TPT) menggunakan metode GTWR disajikan sebagai berikut:




Gambar 2a. Variabel Berpengaruh 2019




Gambar 3b. Variabel Berpengaruh 2020



Gambar 4c. Variabel Berpengaruh 2021



Gambar 5d. Variabel Berpengaruh 2022



Gambar 6e. Variabel Berpengaruh 2023

Hasil analisis GTWR menunjukkan bahwa terdapat variasi spasial-temporal dalam pengaruh variabel independen terhadap tingkat pengangguran di Indonesia. Persebaran variabel yang berpengaruh berbeda-beda tergantung pada lokasi dan tahun pengamatan. Beberapa provinsi dipengaruhi oleh seluruh variabel secara signifikan, sementara provinsi lainnya hanya dipengaruhi oleh sebagian variabel. Hal ini menunjukkan bahwa karakteristik wilayah dan dinamika waktu memiliki peran penting dalam menjelaskan faktor-faktor yang memengaruhi tingkat pengangguran.

Hasil uji kesesuaian model GTWR dengan fungsi pembobot *adaptive tricube* pada tingkat signifikansi $\alpha = 5\%$ (0,05) menghasilkan nilai F_{hitung} sebesar 191,8244, yang melebihi nilai F_{tabel} (0,05;1;164) = 3,8987. Dengan demikian, keputusan yang diambil adalah menolak H_0 , yang menunjukkan terdapat perbedaan yang signifikan antara model GWR dan model GTWR. Sedangkan pengujian parameter model GTWR dengan fungsi pembobot *adaptive tricube* secara parsial dilakukan pada tingkat signifikansi $\alpha = 5\%$ (0,05). Pengujian dilakukan dengan menganalisis nilai t_{hitung} pada setiap lokasi pengamatan. Dengan nilai t_{tabel} sebesar 1,9740. Apabila $t_{hitung} > t_{tabel}$ (0,025;170) = 1,9740, maka keputusan yang diambil adalah untuk menolak H_0 , yang mengindikasikan bahwa variabel independen memiliki pengaruh yang signifikan terhadap variabel dependen.

Setiap variabel independen (PDRB, IPM, RLS, UMP, dan Gini Rasio) menunjukkan pengaruh yang bervariasi terhadap tingkat pengangguran, tergantung pada lokasi dan waktu. PDRB umumnya berdampak negatif, namun dapat pula berdampak positif di wilayah tertentu. IPM dan RLS kadang berpengaruh positif karena ketidaksesuaian antara tingkat pendidikan dan ketersediaan lapangan kerja, serta tingginya ekspektasi pencari kerja berpendidikan tinggi. UMP sebagian besar berdampak positif terhadap pengangguran, namun di beberapa daerah bisa berdampak negatif ketika pasar kerja mampu menyesuaikan secara produktif. Sementara itu, Gini Rasio cenderung berdampak negatif karena



tingginya ketimpangan yang didorong oleh dominasi sektor informal. Temuan ini menegaskan pentingnya pendekatan spasial-temporal dalam menganalisis pengangguran secara lebih akurat dan kontekstual.

3.6. Pemilihan Model Terbaik

Setelah dilakukan estimasi dan pengujian parameter, pada tahap selanjutnya dilakukan pemilihan model terbaik berdasarkan kriteria nilai *R-squared* (R^2) terbesar, nilai AIC (*Akaike Information Criterion*) terkecil, dan nilai MAPE (*Mean Absolute Percentage Error*) terkecil. Perbandingan antara model Regresi Linear, GWR, dan GTWR dilakukan untuk mengidentifikasi keunggulan dan kelemahan masing-masing model dalam menggambarkan variasi spasial dan temporal. Tabel berikut menunjukkan hasil perbandingan kinerja ketiga model.

Tabel 1. Pemilihan Model Terbaik			
Metode	<i>R-Square</i>	AIC	MAPE
Regresi Linear	0,4085	598,5520	21,5157
GWR	0,8504	352,2341	10,6958
GTWR	0,9776	196,8463	3,1626

Berdasarkan hasil evaluasi, model GTWR menunjukkan performa terbaik dengan *R-squared* tertinggi (97,76%), AIC terendah (196,8463), dan MAPE terkecil (3,1626), mengungguli GWR dan Regresi Linear. Temuan ini menegaskan bahwa GTWR paling efektif dalam menangkap variasi spasial-temporal, sehingga dipilih sebagai model regresi optimal dalam penelitian ini.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa model terbaik untuk menganalisis pengangguran di Indonesia adalah GTWR, dengan kinerja optimal (AIC = 196,8463; $R^2 = 0,9776$; MAPE = 3,1626). Hasil analisis mengungkapkan adanya variasi spasial-temporal dalam pengaruh variabel independen terhadap pengangguran, di mana pengaruh tiap variabel berbeda antar provinsi dan waktu. Setiap variabel (PDRB, IPM, RLS, UMP, dan Gini Rasio) memberikan dampak yang tidak seragam, mencerminkan pentingnya pendekatan spasial-temporal untuk memahami dan merumuskan kebijakan pengangguran secara lebih akurat.

REFERENSI

1. C. N. Rianda, “Analisis Dampak Pengangguran Berpengaruh Terhadap Individual,” *AT-TASYRI’ JURNAL ILMIAH PRODI MUAMALAH*, vol. 12, no. 1, p. 17, Jul. 2020, doi: 10.47498/tasyri.v12i01.358.
2. A. N. Septiyana *et al.*, “Pemodelan Geographically Weighted Regression pada Tingkat Pengangguran Terbuka di Pulau Jawa Tahun 2020,” *Seminar Nasional Official Statistics*, vol. 2023, no. 1, pp. 737–746, Oct. 2023, doi: 10.34123/semnasoffstat.v2023i1.1789.
3. Badan Pusat Statistik, “Keadaan Ketenagakerjaan Indonesia Agustus 2023.” Accessed: Feb. 05, 2025. [Online]. Available: <https://www.bps.go.id/id>
4. H. Diniyah and L. W. P. Fisabilillah, “Faktor-Faktor yang Mempengaruhi Tingkat Pengangguran di Indonesia,” *Independent: Journal of Economics*, vol. 2, no. 2, pp. 155–168, Jan. 2023, doi: 10.26740/independent.v2i2.50992.
5. M. I. Rizki, F. Gumelar, J. J. Cerelia, T. Ammar, and A. Nugraha, “Pemodelan Regresi Data Panel Pada Faktor Yang Mempengaruhi Tingkat Pengangguran Terbuka Di Jawa Barat,” *Prosiding Seminar Nasional Matematika, Statistika, dan Aplikasinya Terbitan II*, 2022, Accessed: Mar. 06, 2025. [Online]. Available: <https://jurnal.fmipa.unmul.ac.id/index.php/SNMSA/article/view/853>



6. C. R. Oktarina, J. Rizal, F. Faisal, Q. Lioni, and S. Cahya, “Pemodelan IPM di Provinsi Bengkulu dengan Pendekatan Metode Geographically Weighted Regression dan Geographically Temporally Weighted Regression,” *Jurnal EurekaMatika*, vol. 12, no. 1, pp. 23–34, 2024.
7. F. A. Yansi, Noeryanti, and N. Pratiwi, “Pemodelan Geographically Weighted Panel Regression Menggunakan Pembobot Kernel Gaussian Dan Kernel Bi-Square Pada Kemiskinan Di Papua,” *Jurnal Statistika Industri dan Komputasi*, vol. 9, no. 1, pp. 21–31, 2024, doi: 10.34151/statistika.v9i1.4829.
8. a. S. Fotheringham, C. Brunsdon, and M. Charlton, “Geographically Weighted regression: the analysis of spatially varying relationship,” 2002.
9. S. Haryanto, M. N. Aidi, and A. Djuraidah, “Analysis of the Geographically and Temporally Weighted Regression (GTWR) of the GRDP the Construction Sector in Java Island,” 2019.
10. D. N. Gujarati, *Basic Econometrics.*, vol. 82, no. 326. 2003. doi: 10.2307/2230043.
11. W. Gao, C. Zhao, Y. Zeng, and J. Tang, “Exploring the Spatio-Temporally Heterogeneous Impact of Traffic Network Structure on Ride-Hailing Emissions Using Shenzhen, China, as a Case Study,” *Sustainability (Switzerland)*, vol. 16, no. 11, 2024, doi: 10.3390/su16114539.
12. B. Huang, B. Wu, and M. Barry, “Geographically and temporally weighted regression for modeling spatio-temporal variation in house prices,” *International Journal of Geographical Information Science*, vol. 24, no. 3, pp. 383–401, 2010, doi: 10.1080/13658810802672469.
13. N. A. Izati, B. Warsito, and T. Widiarihi, “Prediksi Harga Emas Menggunakan Feed Forward Neural Network Dengan Metode Extreme Learning Machine,” *Jurnal Gaussian*, vol. 8, no. 2, pp. 171–183, 2019, doi: 10.14710/j.gauss.v8i2.26641.
14. H. T. M. Waibusi, G. M. Tinungki, and S. Sahriman, “Estimasi Parameter Regresi Ridge Robust pada Data Profil Kesehatan Sulawesi Selatan,” *ESTIMASI: Journal of Statistics and Its Application*, vol. 5, no. 2, pp. 169–183, 2024, doi: 10.20956/ejsa.v5i2.25520.