

PEMODELAN *GEOGRAPHICALLY NEURAL NETWORK WEIGHTED REGRESSION* PADA  
TINGKAT PENGANGGURAN TERBUKA DI INDONESIA

**Laura Christin Wunarso**

Program Studi Statistika, FMIPA, Universitas Hasanuddin, Makassar, Indonesia  
email: [laurachristin24@gmail.com](mailto:laurachristin24@gmail.com)

**Hendrikus Aldi Rezky Murtika**

Program Studi Statistika, FMIPA, Universitas Hasanuddin, Makassar, Indonesia  
email: [hendrikus.aldi@gmail.com](mailto:hendrikus.aldi@gmail.com)

**Muhammad Al Faridzi**

Program Studi Statistika, FMIPA, Universitas Hasanuddin, Makassar, Indonesia  
email: [muhammad.alferis@gmail.com](mailto:muhammad.alferis@gmail.com)

**Danu Raihan Muhammad Faisal**

Program Studi Statistika, FMIPA, Universitas Hasanuddin, Makassar, Indonesia  
email: [danuraihan10@gmail.com](mailto:danuraihan10@gmail.com)

**Arifah Raflina Riyadini**

Program Studi Statistika, FMIPA, Universitas Hasanuddin, Makassar, Indonesia  
email: [arifahraflinar@gmail.com](mailto:arifahraflinar@gmail.com)

**Muhammad Alif Fatur Rahman**

Program Studi Statistika, FMIPA, Universitas Hasanuddin, Makassar, Indonesia  
email: [af9206711@gmail.com](mailto:af9206711@gmail.com)

**Siswanto**

Program Studi Statistika, FMIPA, Universitas Hasanuddin, Makassar, Indonesia  
email: [siswanto@unhas.ac.id](mailto:siswanto@unhas.ac.id)

**Abstrak**

Tingkat Pengangguran Terbuka (TPT) di Indonesia masih menjadi isu strategis dalam pembangunan ekonomi karena mencerminkan ketidakseimbangan antara pertumbuhan angkatan kerja dan ketersediaan lapangan kerja. Ketimpangan wilayah serta perbedaan kondisi sosial ekonomi antar daerah menyebabkan variasi spasial dalam tingkat pengangguran yang belum sepenuhnya dapat dijelaskan oleh model regresi klasik. Penelitian ini bertujuan untuk memodelkan faktor-faktor yang memengaruhi TPT di 512 kabupaten/kota di Indonesia tahun 2024 serta membandingkan performa beberapa pendekatan spasial. Metode yang digunakan adalah *Geographically Neural Network Weighted Regression* (GNNWR). Hasil menunjukkan bahwa setiap wilayah memiliki nilai koefisien pengaruh yang berbeda, menandakan adanya heterogenitas spasial pengaruh variabel terhadap TPT. Pada model GNNWR, variabel Indeks Pembangunan Manusia (IPM), Rata-rata Lama Sekolah (RLS), Persentase Penduduk Miskin (PPM), dan Tingkat Partisipasi Angkatan Kerja (TPA) berpengaruh signifikan terhadap TPT. Model GNNWR juga memberikan performa terbaik dengan nilai  $R^2$  sebesar 0,68 (*training*) dan 0,61 (*testing*), AICc terendah (876,33), serta MAPE terkecil (20,01%). Hasil ini menunjukkan bahwa integrasi pendekatan spasial dan *neural network* pada model GNNWR mampu menangkap hubungan nonlinier dan meningkatkan akurasi prediksi TPT antarwilayah.

**Kata Kunci:** Geographically Neural Network Weighted Regression, Heterogenitas Spasial, Tingkat Pengangguran Terbuka

**Abstract**

*The Open Unemployment Rate (OUR) in Indonesia remains a strategic issue in economic development, as it reflects the imbalance between the growth of the labor force and the availability of job opportunities. Regional disparities and*

differences in socioeconomic conditions across areas lead to spatial variation in unemployment rates that cannot be fully explained by classical regression models. This study aims to model the factors influencing the OUR in 512 regencies/municipalities in Indonesia in 2024 and to compare the performance of several spatial approaches. The method employed is Geographically Neural Network Weighted Regression (GNNWR). The results show that each region has different coefficient values, indicating spatial heterogeneity in the effects of variables on the OUR. In the GNNWR model, the Human Development Index (HDI), Mean Years of Schooling (MYS), Percentage of Poor Population (PPP), and Labor Force Participation Rate (LFPR) have a significant effect on the OUR. The GNNWR model also provides the best performance, with an  $R^2$  of 0.68 (training) and 0.61 (testing), the lowest AICc (876.33), and the smallest MAPE (20.01%). These results indicate that integrating spatial approaches and neural networks in the GNNWR model is able to capture nonlinear relationships and improve the accuracy of interregional OUR predictions.

**Keywords:** Geographically Neural Network Weighted Regression, Spatial Heterogeneity, Open Unemployment Rate.

## PENDAHULUAN

Tingkat Pengangguran Terbuka (TPT) merupakan indikator utama yang mencerminkan dinamika ekonomi dan sosial suatu wilayah karena menunjukkan proporsi angkatan kerja yang belum memperoleh pekerjaan meskipun aktif mencari kerja. TPT dipengaruhi oleh berbagai faktor, antara lain pertumbuhan ekonomi, tingkat pendidikan, dan kondisi sosial budaya masyarakat (Munawaroh et al., 2025). Berdasarkan data Badan Pusat Statistik (BPS) tahun 2025, TPT Indonesia tercatat sebesar 4,76% dengan variasi antarprovinsi yang cukup besar. Provinsi Bali memiliki TPT terendah sebesar 1,58%, sedangkan Provinsi Papua mencapai 6,92%. Perbedaan tingkat pengangguran antar daerah menunjukkan pentingnya analisis untuk mengetahui faktor-faktor yang memengaruhi TPT di setiap wilayah. Secara umum, hubungan antara TPT dan faktor sosial ekonomi dapat dianalisis menggunakan model regresi *Ordinary Least Squares* (OLS). Namun, efektivitas model ini menurun ketika terdapat kondisi heterogenitas spasial, yaitu perbedaan karakteristik antar wilayah yang menyebabkan pengaruh suatu faktor tidak sama di setiap daerah (Ma et al., 2021). Kondisi ini membuat OLS kurang mampu menggambarkan variasi spasial dan hubungan antar variabel secara akurat di tingkat lokal.

Dalam upaya mengatasi permasalahan tersebut, pendekatan *Geographically Weighted Regression* (GWR) telah banyak digunakan untuk menganalisis hubungan antar variabel yang bersifat lokal dan tidak stasioner secara spasial. Metode ini memungkinkan setiap lokasi memiliki parameter regresi yang berbeda, sehingga hubungan antara variabel dapat ditelusuri secara lebih mendalam pada tingkat lokal. Namun demikian, GWR memiliki keterbatasan dalam menangani hubungan nonlinier yang kompleks dan dalam menentukan fungsi

pembobot spasial yang optimal (Koç, 2022). Selain itu, struktur pembobot yang digunakan sering kali bersifat statis dan tidak mampu menyesuaikan diri terhadap pola spasial yang dinamis dan kompleks (Dai et al., 2022).

Beberapa pendekatan lanjutan telah dikembangkan untuk mengatasi keterbatasannya, khususnya dalam menangkap variasi pengaruh antar variabel pada skala spasial yang berbeda. Salah satu di antaranya adalah *Multiscale Geographically Weighted Regression* (MSGWR) yang memungkinkan setiap variabel independen memiliki *bandwidth* berbeda. Dengan demikian, MSGWR mampu menggambarkan pengaruh variabel yang bekerja pada skala lokal maupun regional secara lebih akurat dibanding GWR yang menggunakan satu *bandwidth* untuk seluruh variabel (Ardhani et al., 2023).

Selain itu, pendekatan *Nonparametric Geographically Weighted Regression* (NGWR) juga muncul sebagai pengembangan yang lebih fleksibel. NGWR tidak bergantung pada bentuk fungsi linier tertentu, sehingga dapat menangkap hubungan nonlinier antar variabel dan memperhalus pola spasial yang kompleks. Penelitian oleh Saputri et al. (2023) menunjukkan bahwa NGWR mampu memberikan hasil estimasi yang lebih baik dibandingkan GWR dalam memodelkan tingkat pengangguran terbuka di Indonesia. Meskipun demikian, baik MSGWR maupun NGWR masih memiliki keterbatasan dalam hal kemampuan adaptasi terhadap pola spasial yang dinamis dan kompleks.

Seiring dengan perkembangan kecerdasan buatan, muncul metode baru yang mengatasi kekurangan GWR melalui integrasi prinsip regresi spasial dengan jaringan saraf tiruan, yaitu *Geographically Neural Network Weighted Regression* (GNNWR). Du et al. (2020) memperkenalkan

GNNWR sebagai metode yang mampu menghasilkan estimasi yang lebih akurat dibandingkan dengan GWR maupun model linier konvensional dalam mengidentifikasi nonstasioneritas spasial. Metode ini memperluas kemampuan GWR dalam memodelkan hubungan spasial nonlinier dengan memanfaatkan *spatially weighted neural network* (SWNN). GNNWR mengatasi keterbatasan GWR dan MGWR, seperti ketergantungan pada skema pembobot berbasis jarak tetap dan asumsi linearitas, dengan menggunakan jaringan saraf untuk mempelajari fungsi pembobot spasial secara dinamis. Hal ini memungkinkan model untuk menangkap hubungan nonlinier dan proses geografis yang kompleks secara lebih fleksibel.

Penerapan GNNWR telah menunjukkan kinerja yang unggul pada berbagai bidang penelitian. Misalnya, Wang et al. (2022) menerapkan GNNWR dalam pemodelan harga properti di Shenzhen, Tiongkok, dan menemukan bahwa metode ini mampu menangkap variasi spasial harga rumah secara lebih presisi dibandingkan GWR. Selain itu, Ge et al. (2024) menggunakan GNNWR untuk *downscaling* curah hujan berbasis data satelit TRMM di Provinsi Sichuan, dan hasilnya menunjukkan peningkatan akurasi prediksi pada wilayah dengan topografi kompleks.

Walaupun metode GNNWR telah banyak digunakan dalam bidang ekonomi dan lingkungan, penerapannya pada konteks sosial ekonomi, khususnya TPT di Indonesia masih relatif terbatas. Oleh karena itu, penelitian ini menghadirkan pendekatan baru dengan menggunakan GNNWR untuk kasus TPT. Penggunaan GNNWR pada penelitian ini sekaligus mengatasi keterbatasan model sebelumnya seperti GWR, MGWR, dan NGWR dalam menangkap hubungan nonlinier dan adaptif terhadap variasi spasial, sehingga estimasi pengaruh faktor sosial-ekonomi terhadap TPT dapat dilakukan lebih presisi di tingkat lokal.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk memodelkan faktor-faktor sosial ekonomi yang memengaruhi TPT di Indonesia menggunakan GNNWR. Secara khusus, penelitian ini bertujuan untuk: (1) mengidentifikasi faktor-faktor sosial ekonomi yang berpengaruh terhadap TPT pada tingkat lokal; (2) membandingkan performa model GNNWR dengan GWR dan model

regresi global; serta (3) menyajikan peta distribusi spasial pengaruh variabel penentu TPT di berbagai wilayah. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan analisis spasial berbasis kecerdasan buatan dalam perumusan kebijakan ketenagakerjaan dan pembangunan ekonomi daerah yang lebih kontekstual.

## KAJIAN TEORI

### TINGKAT PENGANGGURAN TERBUKA

Tingkat Pengangguran Terbuka (TPT) merupakan indikator yang digunakan untuk mengukur proporsi angkatan kerja yang sedang mencari pekerjaan namun belum memperoleh pekerjaan pada periode tertentu. Menurut Badan Pusat Statistik (BPS) tahun 2023, TPT didefinisikan sebagai persentase jumlah pengangguran terhadap total angkatan kerja. Indikator ini sering digunakan untuk menilai kondisi pasar tenaga kerja dan menjadi salah satu ukuran penting dalam menilai efektivitas pembangunan ekonomi.

Secara umum, pengangguran terbuka menggambarkan situasi di mana seseorang termasuk dalam kategori angkatan kerja aktif tetapi tidak memiliki pekerjaan, sedang mencari pekerjaan, atau mempersiapkan usaha (ILO, 2022). Definisi ini menekankan bahwa TPT tidak hanya mencakup individu yang tidak bekerja sama sekali, tetapi juga mereka yang secara aktif berusaha untuk mendapatkan pekerjaan.

Dalam konteks makroekonomi, tingkat pengangguran terbuka sering dipandang sebagai salah satu indikator kesehatan ekonomi suatu negara. Tingginya TPT mencerminkan adanya ketidakseimbangan antara penawaran dan permintaan tenaga kerja (World Bank, 2021). Selain itu, TPT juga dapat menggambarkan efektivitas kebijakan pemerintah dalam menciptakan lapangan kerja dan menjaga stabilitas pasar tenaga kerja.

### UJI HETEROGENITAS SPASIAL

Pemodelan regresi terhadap data spasial diawali dengan pengujian heterogenitas spasial. Hal ini dilakukan untuk melihat adanya keragaman antar lokasi yang disebabkan suatu lokasi memiliki struktur dan parameter hubungan yang berbeda dengan lokasi lainnya. Menurut Suciptawati et al. (2023), heterogenitas data secara spasial dapat diuji dengan menggunakan uji Breusch-Pagan yang memiliki hipotesis sebagai berikut:

$$H_0 : \sigma_{u_1, v_1}^2 = \sigma_{u_2, v_2}^2 = \dots = \sigma_{u_n, v_n}^2 = \sigma^2$$

artinya tidak terdapat heterogenitas spasial atau memiliki ragam yang sama (homoskedastisitas)

$H_1$  : minimal ada satu  $\sigma_{u_i, v_i}^2 \neq \sigma^2$  artinya terdapat heterogenitas spasial atau ragam tidak sama (heteroskedastisitas)

Adapun statistik uji Breusch-Pagan dinyatakan pada Persamaan (1)

$$BP = \left(\frac{1}{2}\right) \mathbf{h}^T \mathbf{Z} (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{h} + \left(\frac{1}{\text{tr}}\right) \left[ \frac{\mathbf{e}^T \mathbf{W} \mathbf{e}}{\sigma^2} \right]^2 \quad (1)$$

dengan

- $\mathbf{h}$  : vektor dengan elemen  $h_i = \left(\frac{e_i^2}{\sigma^2} - 1\right)$
- $\mathbf{e}$  : vektor galat  $e_i$  (galat untuk pengamatan ke- $i$ )
- $\sigma^2$  : ragam galat
- $\text{tr}$  : *trace* matriks  $[\mathbf{W}^T \mathbf{W} + \mathbf{W}^2]$   
matriks pembobot antara lokasi ke- $i$  dan  $j$
- $\mathbf{W}$  : dengan fungsi pembobot *Adaptive Gaussian Kernel* dalam pemodelan GWR.
- $\mathbf{Z}$  : matriks  $\mathbf{X}$  berukuran  $n \times (p + 1)$  yang sudah dinormalbakukan

Adapun kriteria pengujian adalah tolak  $H_0$  jika  $BP > \chi_{p+1}^2$ .

### UJI MULTIKOLINERITAS

Multikolinearitas merupakan kondisi dalam analisis regresi ketika terdapat hubungan linier yang kuat antar variabel independen, sehingga dapat mengganggu kestabilan estimasi parameter regresi. Menurut Gujarati dan Porter (2020), multikolinearitas yang tinggi menyebabkan kesulitan dalam mengisolasi pengaruh masing-masing variabel bebas terhadap variabel dependen. Salah satu metode yang umum digunakan untuk mendeteksi adanya multikolinearitas adalah *Variance Inflation Factor* (VIF). VIF mengukur seberapa besar variansi dari suatu koefisien regresi meningkat akibat adanya korelasi dengan variabel bebas lainnya (Akinwande et al., 2021). Semakin tinggi nilai VIF, semakin besar indikasi adanya multikolinearitas pada model regresi.

Secara umum, nilai  $VIF > 10$  sering dijadikan indikasi adanya multikolinearitas yang serius (Hair et al., 2021). Adapun VIF dapat dihitung dengan Persamaan (2)

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

dengan  $R_j^2$  adalah koefisien determinasi antara  $X_j$  dengan variabel bebas lainnya pada persamaan model dugaan untuk  $j = 1, 2, \dots, p$ .

### REGRESI ORDINARY LEAST SQUARES

*Ordinary Least Squares* (OLS) merupakan metode estimasi parameter dalam regresi linier yang paling banyak digunakan karena sederhana dan efisien. OLS bekerja dengan cara meminimalkan jumlah kuadrat selisih antara nilai observasi dan prediksi model (Wooldridge, 2020). Menurut Greene (2020), OLS dapat memberikan estimasi yang tidak bias dan konsisten apabila asumsi klasik terpenuhi, seperti normalitas, homoskedastisitas, tidak adanya multikolinearitas sempurna, serta tidak adanya autokorelasi. Adapun parameter regresi OLS dapat diestimasi melalui Persamaan (3)

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (3)$$

dengan

- $\hat{\beta}$  : vektor estimasi parameter regresi
- $\mathbf{Y}$  : vektor variabel dependen
- $\mathbf{X}$  : matriks variabel independen

### GEOGRAPHICALLY WEIGHTED REGRESSION

*Geographically Weighted Regression* (GWR) merupakan pengembangan dari regresi OLS yang dirancang untuk menangani masalah heterogenitas spasial (Wang et al., 2024). Metode ini memungkinkan parameter regresi bervariasi sesuai dengan koordinat lokasi, sehingga memberikan hasil estimasi yang lebih akurat dibandingkan model regresi global. Secara umum, model GWR dituliskan pada Persamaan (4)

$$y_i = \beta_0(u_i, v_i) + \sum_{k=1}^p \beta_k(u_i, v_i) x_{ik} + \varepsilon_i \quad (4)$$

dengan

- $y_i$  : variabel dependen
- $\beta_k(u_i, v_i)$  : koefisien regresi lokal pada lokasi  $(u_i, v_i)$
- $x_{ik}$  : variabel independen ke- $k$  pada lokasi  $i$ ,
- $\varepsilon_i$  : *error*

Dalam bentuk matriks, estimator GWR dinyatakan pada Persamaan (5)

$$\hat{\beta}(u_i, v_i) = (\mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{Y} \quad (5)$$

dengan  $W(u_i, v_i)$  merupakan matriks bobot spasial berbentuk diagonal yang ditentukan oleh fungsi pembobot *kernel*.

**FUNGSI PEMBOBOT SPASIAL**

Dalam GWR, fungsi pembobot digunakan untuk memberikan bobot berbeda pada setiap observasi berdasarkan jaraknya dengan titik lokasi  $(u_i, v_i)$ . Observasi yang lebih dekat diberi bobot lebih besar, sedangkan observasi yang jauh bobotnya semakin kecil (Comber et al., 2021). Penelitian ini membandingkan tiga fungsi pembobot *kernel* antara lain sebagai berikut.

1. *Adaptive Gaussian Kernel*

*Kernel Gaussian* bersifat halus dan bobotnya menurun secara eksponensial dengan bertambahnya jarak (Chen et al., 2022). Fungsi *Adaptive Gaussian Kernel* dinyatakan pada Persamaan (6):

$$w_{ij}(u_i, v_i) = \exp\left(-\frac{d_{ij}^2}{2b^2}\right) \tag{6}$$

$d_{ij}$  : jarak antara titik  $i$  dan  $j$   
 $b$  : parameter *bandwidth* adaptif dengan

$$d_{ij} = \sqrt{(u_i - u_j)^2 + (v_i - v_j)^2}$$

2. *Adaptive Bisquare Kernel*

*Kernel bisquare* memberikan bobot nol jika jarak melebihi *bandwidth*  $b$  (Wang et al., 2024). Fungsi *Adaptive Bisquare Kernel* dinyatakan pada Persamaan (7):

$$w_{ij}(u_i, v_i) = \begin{cases} \left(1 - \left(\frac{d_{ij}}{b}\right)^2\right)^2, & d_{ij} < b \\ 0, & d_{ij} \geq b \end{cases} \tag{7}$$

3. *Adaptive Exponential Kernel*

*Kernel exponential* menurunkan bobot lebih cepat dibanding *Gaussian* (Liu dan Goudie, 2023). Fungsi *Adaptive Exponential Kernel* dinyatakan pada Persamaan (8):

$$w_{ij}(u_i, v_i) = \exp\left(-\frac{d_{ij}}{b}\right) \tag{8}$$

Adapun besarnya pengaruh lokasi di sekitar titik pusat terhadap estimasi parameter pada titik ke- $i$  ditentukan oleh nilai *bandwidth* yang digunakan. *Bandwidth* optimal dipilih berdasarkan nilai *bandwidth* yang menghasilkan nilai *Cross Validation* (CV) terkecil (Prameswari et al., 2025). CV dapat dihitung menggunakan Persamaan (9):

$$CV(b) = \sum_{i=1}^n (y_i - \hat{y}_{\neq i}(b))^2 \tag{9}$$

**GEOGRAPHICALLY NEURAL NETWORK WEIGHTED REGRESSION**

*Geographically Neural Network Weighted Regression* (GNNWR) merupakan pengembangan dari *Geographically Weighted Regression* (GWR) yang dirancang untuk menangani masalah nonstasionaritas spasial sekaligus hubungan nonlinear dalam data geografis. Tidak seperti GWR tradisional yang hanya mengandalkan fungsi *kernel* sebagai bobot spasial, GNNWR memanfaatkan jaringan saraf untuk membentuk bobot spasial secara adaptif berdasarkan data, sehingga menghasilkan estimasi yang lebih akurat pada fenomena kompleks (Yin et al., 2024).

*Neuron* dalam jaringan saraf tiruan yang menjadi inti dari pembobotan spasial pada GNNWR memiliki parameter. (Ni et al., 2022). Berikut ini parameter dan *hyperparameter* yang menggambarkan suatu *neuron* (Yin et al., 2024; Cheng et al., 2022; Hwang et al., 2024; Li et al., 2024; ).

1. *Input layer*

Lapisan *input* menerima variabel  $x_1, x_2, \dots, x_n$  sebagai fitur, dengan bobot  $w_1, w_2, \dots, w_n$  yang terhubung ke setiap *neuron*. Ditambahkan bias  $x_0 = 1$  dengan bobot  $w_0$  untuk menambah fleksibilitas sebagaimana ditunjukkan pada Persamaan (10)

$$z = \sum_{i=0}^n w_i x_i \tag{10}$$

2. *Hidden Layer*

*Neuron* pada *hidden layer* menerima hasil perhitungan  $z$  dari *input layer*, lalu melalui fungsi aktivasi nonlinear. Hal ini memungkinkan jaringan menangkap hubungan nonlinear. *Neuron layer* dinyatakan pada Persamaan (11)

$$h_j = f \left( \sum_{i=0}^n w_{ij}x_i + b_j \right) \quad (11)$$

dengan  $h_j$  adalah *output hidden neuron* ke- $j$ ,  $b_j$  adalah bias, dan  $f(\cdot)$  adalah fungsi aktivasi.

3. *Output Layer*

*Output layer* menggabungkan sinyal dari *hidden layer* untuk menghasilkan prediksi  $y$ . *Output layer* ditunjukkan pada Persamaan (12)

$$y = f_{out} \left( \sum_{j=1}^m v_j h_j + b \right) \quad (12)$$

dengan  $v_j$  adalah bobot dari *hidden layer* ke *output*,  $m$  menyatakan jumlah *neuron hidden*, dan  $f_{out}$  adalah fungsi aktivasi *output*.

4. *Learning Rate* ( $\alpha$ )

*Learning rate* mengatur besar langkah pembaruan bobot dalam optimisasi. *Learning rate* dinyatakan pada Persamaan (13)

$$w^{(t+1)} = w^{(t)} - \alpha \cdot \nabla L(w^{(t)}) \quad (13)$$

5. *Epoch*

*Epoch* menunjukkan berapa kali seluruh dataset digunakan untuk memperbarui bobot. Misalnya, 50 *epoch* berarti seluruh data latih sudah digunakan sebanyak 50 kali.

6. *Batch Size*

*Batch size* menentukan jumlah sampel yang diproses sebelum *update* bobot. *Batch size* dinyatakan pada Persamaan (14)

$$\nabla L(w) = \frac{1}{m} \sum_{i=1}^m \nabla l_i(w) \quad (14)$$

7. *Regularisasi Dropout*

*Dropout* digunakan untuk mencegah *overfitting*. *Dropout* dilakukan dengan menonaktifkan *neuron* secara acak dengan probabilitas  $p$ . *Dropout* dinyatakan pada Persamaan (15)

$$h_j = \begin{cases} 0 \\ z_j \\ 1-p \end{cases} \quad (15)$$

8. *Adam Optimizer*

*Optimizer* mengatur cara bobot diperbarui berdasarkan gradien. Salah satu metode populer adalah Adam, yang memadukan momentum dan RMSProp. Rumus *Adam Optimizer* dinyatakan pada Persamaan (16)

$$w_{t+1} = w_t - \alpha \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \varepsilon}} \quad (16)$$

Dengan


$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) \nabla L(w_t) \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) (\nabla L(w_t))^2 \\ \hat{m}_t &= \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t &= \frac{v_t}{1 - \beta_2^t} \end{aligned}$$

GNNWR merancang SWNN yang berfungsi untuk mewujudkan ekspresi fungsi *kernel* bobot menggunakan jaringan saraf. Secara spesifik, SWNN mengambil jarak spasial antar titik sebagai lapisan input dan matriks bobot spasial sebagai lapisan *output* dengan jumlah *hidden layer* yang dipilih disesuaikan dengan kebutuhan pemodelan. Perhitungan bobot spasial dari titik-titik ini bersesuaian dengan Persamaan (17)

$$w_{ij} = g(\mathbf{X}_{ij}; \Theta) \quad (17)$$

dengan  $\mathbf{x}_{ij}$  bisa berupa vektor *input* untuk SWNN dan  $\Theta$  adalah parameter jaringan. Fungsi  $g(\cdot)$  adalah fungsi aktivasi.

Adapun model GNNWR dinyatakan pada Gambar 1.



Gambar 1. Model GNNWR (Du et al., 2020).

**UJI NONSTATIONERITAS**

Uji ini digunakan untuk menguji stasioneritas (kekonstanan) hubungan antara variabel independen dan dependen di setiap lokasi (Du et al., 2020). Hipotesis uji nonstasioneritas dinyatakan sebagai berikut:

$$H_0: \beta_k(u_i, v_i) = \beta_k; k = 1, 2, \dots, p; i = 1, 2, \dots, p$$

$$H_1: \text{minimal ada satu } \beta_k(u_i, v_i) \neq \beta_k$$

Statistik uji diberikan pada Persamaan (18):

$$F_1 = \frac{DSS/\delta_i}{SSE(H_1)/df_2} \quad (18)$$

dengan

$$DSS = SSE(H_0) - SSE(H_1) = \mathbf{y}^T((\mathbf{I} - \mathbf{H}) - (\mathbf{I} - \mathbf{S})^T(\mathbf{I} - \mathbf{S}))\mathbf{y}$$

$$\delta_i = tr([(I - H) - (I - S)^T(I - S)]^i), i = 1, 2$$

$$df_1 = \delta_1^2 / \delta_2$$

$$df_2 = n - p - 1$$

Adapun kriteria pengujian yaitu tolak  $H_0$  jika  $F_1 < F_{1-\alpha}(df_1, df_2)$

**UJI SIGNIFIKANSI PARAMETER**

Uji ini digunakan untuk mengevaluasi signifikansi parameter pada tingkat lokal (*location-specific*). Artinya, apakah pada suatu lokasi tertentu, koefisien regresi variabel independen signifikan memengaruhi variabel dependen (Du et al., 2020). Hipotesis uji F2 signifikansi parameter dinyatakan sebagai berikut.

$$H_0: \beta_k(u_i, v_i) \text{ tidak signifikan}$$

$$H_1: \beta_k(u_i, v_i) \text{ signifikan}$$

Untuk setiap lokasi  $i$ , uji lokal apakah koefisien  $\beta_j(u_i, v_i)$  signifikan ( $\neq 0$ ) dapat dihitung menggunakan Persamaan (19):

$$F_2(k) = \frac{V_k^2}{\hat{\sigma}^2} \tag{19}$$

dengan

$$V_k^2 = \frac{1}{n} \sum_{i=1}^n \left( \hat{\beta}_{ik} - \frac{1}{n} \sum_{i=1}^n \hat{\beta}_{ik} \right)^2$$

$$\gamma_{ik} = tr \left\{ \left[ \frac{1}{n} B_k^T \left( I - \frac{1}{n} J \right) B_k \right]^i \right\}, i = 1, 2, \dots, n$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Adapun kriteria pengujian yaitu tolak  $H_0$  jika  $F_2(k) > F_{\alpha} \left( \frac{\gamma_{1k}}{\gamma_{2k}}, \frac{\delta_1^2}{\delta_2} \right)$

**EVALUASI KINERJA MODEL**

Dalam penelitian ini digunakan tiga ukuran evaluasi model, yaitu *Akaike Information Criterion Corrected* (AICc), *Mean Absolute Percentage Error* (MAPE), dan Koefisien Determinasi ( $R^2$ ).

1. *Akaike Information Criterion Corrected* (AICc)  
AICc adalah modifikasi dari *Akaike Information Criterion* (AIC) yang mengoreksi bias ketika jumlah sampel relatif kecil dibanding jumlah parameter model (Portet, 2020). Rumus AICc diberikan pada Persamaan (20):

$$AICc = AIC + \frac{2k(k+1)}{n-k-1} \tag{20}$$

dengan

$$AIC = -2 \ln(L) + 2k$$

- $k$  : jumlah parameter model
- $n$  : jumlah sampel
- $L$  : *likelihood* maksimum

Nilai AICc yang lebih kecil menunjukkan model yang lebih baik.

2. *Mean Absolute Percentage Error*

MAPE merupakan ukuran akurasi peramalan atau model regresi dengan menghitung rata-rata persentase kesalahan absolut antara nilai aktual dan nilai prediksi (Chicco et al., 2021). Rumus MAPE dinyatakan pada persamaan (21)

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \tag{21}$$

dengan

- $Y_i$  : nilai aktual observasi ke- $i$
- $\hat{Y}_i$  : nilai prediksi observasi ke- $i$
- $n$  : jumlah observasi

Semakin kecil nilai MAPE, maka semakin baik performa model.

3. *Koefisien Determinasi*

Koefisien determinasi ( $R^2$ ) digunakan untuk mengukur seberapa besar variasi variabel dependen dapat dijelaskan oleh variabel independen dalam model (Chicco et al., 2021). Rumus  $R^2$  diberikan pada Persamaan (22).

$$R^2 = \frac{\sum_i^n (y_i - \hat{y}_i)^2}{\sum_i^n (y_i - \bar{y}_i)^2} \tag{22}$$

Nilai  $R^2$  berada pada rentang 0-1, semakin mendekati 1 menunjukkan model semakin baik dalam menjelaskan variasi data.

**METODE**

**DATA PENELITIAN**

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) tahun 2024. Data ini mencakup 512 kabupaten/kota di seluruh Indonesia. Variabel yang digunakan meliputi Tingkat Pengangguran Terbuka (TPT), Indeks Pembangunan Manusia (IPM), Rata-Rata Lama Sekolah (RLS), Persentase Penduduk Miskin (PPM), serta Tingkat Partisipasi Angkatan Kerja (TPA).

Selain itu, disertakan pula koordinat geografis berupa *longitude* dan *latitude* masing-masing wilayah untuk keperluan analisis spasial.

#### TEKNIK ANALISIS DATA

Pada penelitian ini, analisis data dilakukan dengan menggunakan *software* RStudio 2025.09.1+401 dan Python 3.12.1. Adapun tahapan analisis yang dilakukan antara lain sebagai berikut.

1. Melakukan analisis deskriptif melalui pemetaan spasial untuk menggambarkan sebaran variabel-variabel pada setiap wilayah.
2. Melakukan pengujian asumsi heterogenitas spasial menggunakan uji Breusch-Pagan.
3. Melakukan pengujian asumsi nonmultikolinieritas melalui perhitungan nilai VIF.
4. Melakukan *Splitting* data meliputi data *train* (70%), *test* (15%), dan *validation* (15%).
5. Mengestimasi model GNNWR dengan menentukan *hyperparameter* dan *optimizer* terbaik.
6. Melakukan pengujian nonstasioneritas untuk menilai kestabilan parameter antarwilayah menggunakan  $F_1$  test.
7. Melakukan pengujian signifikansi parameter menggunakan  $F_2$  test.
8. Mengevaluasi kinerja model menggunakan metrik  $R^2$ , MAPE, dan AICc.
9. Melakukan visualisasi hasil melalui peta tematik.

#### HASIL DAN PEMBAHASAN

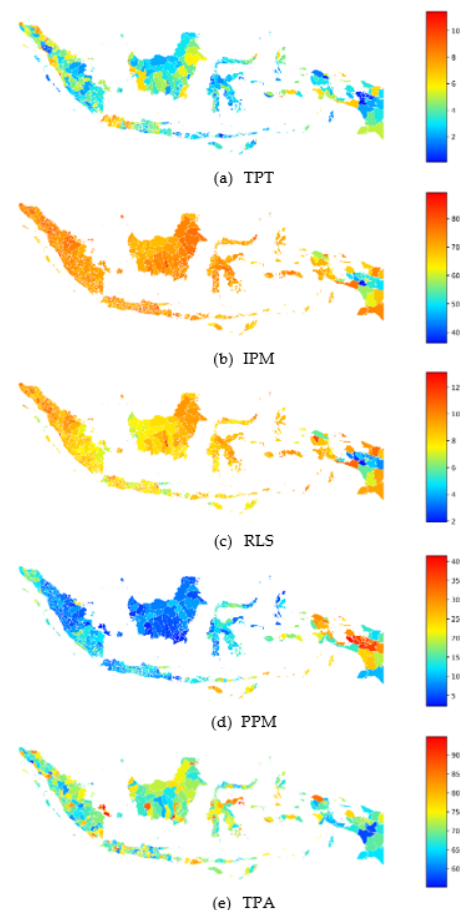
##### EKSPLORASI DATA

Statistik deskriptif digunakan untuk memberikan gambaran umum mengenai karakteristik data dari setiap variabel penelitian. Hasil statistik deskriptif yang meliputi nilai minimum, maksimum, kuartil 1, kuartil 3, dan rata-rata disajikan pada Tabel 1.

Tabel 1. Statistik deskriptif

Variabel	Min	Q1	Mean	Q3	Max
TPT	0,07	2,64	4,13	5,31	11,44
IPM	36,30	70,64	73,21	75,98	89,10
RLS	1,92	7,87	8,76	9,63	13,10
PPM	2,23	6,36	11,19	13,78	41,42
TPA	55,18	67,47	71,48	74,93	94,81

Berdasarkan Tabel 1, variabel TPT memiliki nilai rata-rata (mean) sebesar 4,13%, dengan rentang nilai yang cukup luas antara 0,07% hingga 11,44%. Hal ini menunjukkan bahwa meskipun sebagian besar kabupaten memiliki TPT yang relatif rendah, terdapat beberapa kabupaten yang mengalami tingkat pengangguran yang sangat tinggi. Indeks Pembangunan Manusia (IPM) memiliki nilai rata-rata sebesar 73,21, yang menunjukkan tingkat perkembangan kualitas hidup manusia di Indonesia secara keseluruhan. Selain itu, Rata-Rata Lama Sekolah (RLS) menunjukkan rata-rata durasi pendidikan yang diambil oleh penduduk Indonesia, dengan rata-rata 8,76 tahun. Persentase Penduduk Miskin (PPM) tercatat 11,19%, yang mencerminkan proporsi penduduk yang hidup di bawah garis kemiskinan. Tingkat Partisipasi Angkatan Kerja (TPA) dengan nilai rata-rata 71,48% menunjukkan bahwa sebagian besar penduduk Indonesia aktif dalam angkatan kerja. Pemahaman yang lebih komprehensif mengenai sebaran data antarwilayah dapat diperoleh melalui visualisasi peta spasial sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Peta Persebaran Variabel

Gambar 2 menampilkan peta spasial distribusi beberapa variabel penelitian, yaitu TPT, IPM, RLS, PPM, dan TPA. Berdasarkan Gambar 2a, terlihat bahwa TPT bervariasi antarwilayah, dengan konsentrasi nilai tinggi (warna merah hingga kuning) cenderung terdapat di wilayah perkotaan besar seperti sebagian Jawa dan beberapa kabupaten di Papua, sedangkan wilayah dengan TPT rendah (warna biru hingga hijau) banyak ditemukan di luar Jawa. Pada Gambar 2b, IPM menunjukkan pola yang relatif tinggi di sebagian besar wilayah Jawa dan Bali, menandakan kualitas pembangunan manusia yang lebih baik dibandingkan beberapa wilayah di Indonesia bagian timur yang masih didominasi warna biru. Selanjutnya, Gambar 2c menunjukkan bahwa RLS lebih tinggi di Jawa dan sebagian Sumatra, yang umumnya merupakan daerah dengan akses pendidikan yang lebih baik. Sebaliknya, wilayah Indonesia timur menunjukkan nilai RLS yang lebih rendah. Gambar 2d memperlihatkan bahwa PPM masih tinggi di wilayah-wilayah timur Indonesia, seperti Nusa Tenggara Timur, Maluku, dan Papua, sedangkan daerah dengan PPM rendah didominasi wilayah barat Indonesia. Adapun pada Gambar 2e, TPA cenderung tinggi di sebagian besar wilayah barat, menunjukkan keterlibatan penduduk yang lebih besar dalam pasar kerja. Secara keseluruhan, kelima peta tersebut menunjukkan adanya ketimpangan spasial antarwilayah di Indonesia, baik dalam aspek ekonomi, pendidikan, maupun ketenagakerjaan.

#### PENGUJIAN ASUMSI

Sebelum dilakukan analisis lebih lanjut, terlebih dahulu dilakukan pengujian nonmultikolinieritas untuk memastikan bahwa antarvariabel independen tidak memiliki hubungan linier yang kuat. Hasil uji nonmultikolinieritas menggunakan VIF disajikan pada Tabel 2.

**Tabel 2.** Nilai VIF

Variabel	VIF
IPM	6,70
RLS	4,34
PPM	2,38
TPA	1,03

Berdasarkan Tabel 2, nilai VIF untuk seluruh variabel independen berada di bawah ambang batas 10, yaitu masing-masing sebesar 6,70 untuk IPM,

4,34 untuk RLS, 2,38 untuk PPM, dan 1,03 untuk TPA. Hal ini menunjukkan bahwa tidak terdapat masalah multikolinearitas di antara variabel-variabel independen yang digunakan dalam penelitian. Dengan demikian, seluruh variabel dapat digunakan secara bersamaan dalam model tanpa menimbulkan bias pada hasil estimasi parameter.

Pengujian asumsi selanjutnya adalah pengujian heterogenitas spasial menggunakan uji Breusch-Pagan. Hasil pengujian ini menjadi dasar dalam menentukan perlunya menggunakan model regresi spasial. Hasil uji Heterogenitas Spasial disajikan pada Tabel 3.

**Tabel 3.** Hasil uji Breusch-Pagan

BP	df	<i>p-value</i>
10.312	4	0.035

Berdasarkan Tabel 3, hasil uji Breusch-Pagan menunjukkan nilai statistik sebesar 10,312 dengan derajat bebas (df) sebanyak 4 dan nilai *p-value* sebesar 0,035. Karena nilai *p-value* < 0,05, maka dapat disimpulkan bahwa terdapat heterogenitas spasial yang signifikan dalam data. Artinya, varians residual antarwilayah tidak bersifat homogen, sehingga model regresi global (OLS) kurang tepat untuk menggambarkan hubungan antarvariabel secara menyeluruh. Dengan demikian, diperlukan pendekatan model yang mampu mengakomodasi variasi spasial tersebut, seperti GNNWR.

#### PEMODELAN GNNWR

Sebelum proses pelatihan model dilakukan, perlu ditentukan arsitektur jaringan dan pengaturan hyper-parameter yang digunakan. Tabel 4 menyajikan konfigurasi arsitektur jaringan serta nilai hyper-parameter pada model GNNWR yang digunakan dalam penelitian ini.

**Tabel 4.** Pengaturan arsitektur dan *hyperparameter* untuk model GNNWR

	<i>Input</i>	<i>Hidden 1</i>	<i>Hidden 2</i>	<i>Output</i>
SWNN	256	128	64	5
<i>Hyper parameter</i>	<i>Learning Rate</i>	<i>Max Epoch</i>	<i>Batch Size</i>	<i>Drop -out</i>
	0,1	10.000	64	0,75

Berdasarkan Tabel 4, pengaturan arsitektur dan *hyper-parameter* yang digunakan dalam model GNNWR. Model ini terdiri dari 256 input node yang merepresentasikan jumlah observasi atau fitur spasial, dua *hidden layer* masing-masing dengan 128 dan 64 neuron, serta 5 *output* node yang menunjukkan jumlah variabel target yang diprediksi. Pengaturan *hyper-parameter* model mencakup *learning rate* sebesar 0,1, jumlah maksimum *epoch* sebanyak 10.000, *batch size* 64, dan *dropout rate* sebesar 0,75. Kombinasi pengaturan ini bertujuan untuk meningkatkan kemampuan model dalam melakukan generalisasi dan mencegah overfitting, terutama dalam menangkap pola spasial yang kompleks antar wilayah. Arsitektur ini mencerminkan pendekatan pembelajaran mendalam yang adaptif dalam memodelkan hubungan non-linear dan spasial pada data sosial ekonomi antar kabupaten.

Setelah arsitektur dan *hyper-parameter* model GNNWR ditetapkan, langkah selanjutnya adalah membandingkan kinerja model GNNWR dengan model regresi lainnya, yaitu OLS, GWR-AG, GWR-AE, dan GWR-AB. Perbandingan dilakukan untuk menilai tingkat akurasi dan kemampuan generalisasi masing-masing model pada data *training* dan *testing*. Evaluasi kinerja model diukur menggunakan nilai  $R^2$ , AICc, dan MAPE. Hasil perbandingan kinerja antar model disajikan pada Tabel 5.

**Tabel 5.** Perbandingan hasil model OLS, GWR, dan GNNWR untuk data *training* dan *testing*

Model	Training		Testing	
	$R^2$	AICc	$R^2$	MAPE
OLS	0,23	1.387,88	0,36	32,99%
GWR-AG	0,58	1.288,48	0,54	28,78%
GWR-AE	0,61	1.281,76	0,54	28,73%
GWR-AB	0,52	1.305,23	0,53	30,52%
GNNWR	0,68	876,33	0,61	20,01%

Berdasarkan Tabel 5, model GNNWR memiliki kinerja terbaik dibandingkan model lainnya, dengan nilai  $R^2$  sebesar 0,68 pada data *training* dan 0,61 pada data *testing*, serta nilai AICc yang paling rendah yaitu 876,33. Selain itu, nilai MAPE pada model GNNWR juga paling kecil yaitu 20,01%, yang menunjukkan bahwa model ini memiliki tingkat kesalahan prediksi yang paling rendah. Sebaliknya, model OLS menunjukkan performa yang paling

rendah dengan MAPE sebesar 32,99% dan nilai  $R^2$  *testing* hanya 0,36. Model GWR dengan tiga varian (AG, AE, dan AB) menunjukkan peningkatan performa dibanding OLS, namun masih berada di bawah GNNWR. Hasil ini menegaskan bahwa GNNWR mampu menangkap pola hubungan spasial yang lebih kompleks dan menghasilkan estimasi yang lebih akurat dibandingkan model regresi global maupun regresi spasial konvensional.

Setelah model dibandingkan berdasarkan kinerja prediktifnya, tahap selanjutnya adalah mengidentifikasi tingkat nonstasioneritas spasial dari masing-masing model. Hasil uji nonstasioneritas disajikan pada Tabel 6.

**Tabel 6.** Hasil pengujian nonstasioneritas model GWR dan GNNWR

Model	Testing	
	$F_1$	<i>p-value</i>
GWR-AG	0,6669	< 0,000
GWR-AE	0,6655	< 0,000
GWR-AB	0,7233	< 0,000
GNNWR	0,5322	< 0,000

Berdasarkan Tabel 6, hasil pengujian nonstasioneritas menunjukkan bahwa seluruh model GWR (GWR-AG, GWR-AE, dan GWR-AB) serta model GNNWR secara signifikan menunjukkan adanya ketidakstasioneran spasial pada data yang digunakan. Hal ini ditunjukkan oleh nilai statistik  $F_1$  yang tinggi dan *p-value* kurang dari 0,000 pada semua model. Model GWR-AB memiliki nilai  $F_1$  tertinggi sebesar 0,7233, yang mengindikasikan tingkat nonstasioneritas tertinggi dibandingkan varian GWR lainnya. Namun demikian, model GNNWR menunjukkan nilai  $F_1$  yang lebih rendah sebesar 0,5322, meskipun tetap signifikan secara statistik. Hasil ini memperkuat bahwa model GNNWR mampu mengakomodasi variasi spasial secara signifikan, namun dengan stabilitas yang relatif lebih baik dibandingkan model GWR, mengingat nilai  $F_1$  yang lebih rendah.

Setelah diketahui bahwa model GNNWR memiliki kinerja terbaik dan menunjukkan adanya nonstasioneritas spasial, tahap berikutnya adalah pengujian signifikansi parameter untuk mengetahui variabel yang berpengaruh signifikan terhadap TPT. Hasil pengujian signifikansi parameter model GNNWR ditampilkan pada Tabel 7.

**Tabel 7.** Hasil pengujian signifikansi parameter model GNNWR

Variabel	GNNWR	
	F <sub>2</sub>	p-value
Intercept	51,03	< 0.001
IPM	322,03	< 0.001
RLS	15,53	< 0.001
PPM	25,67	< 0.001
TPA	115,67	< 0.001

Tabel 7 menunjukkan bahwa seluruh parameter dalam model GNNWR signifikan secara statistik terhadap prediksi variabel target. Seluruh variabel independen, termasuk Intercept, memiliki nilai F<sub>2</sub> yang tinggi dengan p-value kurang dari 0,001, yang mengindikasikan bahwa masing-masing parameter berkontribusi secara signifikan dalam membentuk model. Variabel IPM menunjukkan pengaruh terbesar terhadap model dengan nilai F<sub>2</sub> sebesar 322,03, diikuti oleh TPA sebesar 115,67. Hal ini menunjukkan bahwa indeks pembangunan manusia (IPM) dan tingkat partisipasi angkatan kerja (TPA) merupakan faktor dominan dalam menjelaskan variasi spasial dari variabel target. Dengan demikian, model GNNWR tidak hanya unggul dalam menangkap kompleksitas spasial, tetapi juga berhasil mengidentifikasi kontribusi signifikan dari masing-masing faktor sosial ekonomi dalam konteks spasial antar kabupaten.

Setelah diketahui bahwa seluruh variabel dalam model GNNWR berpengaruh signifikan terhadap TPT, tahapan selanjutnya adalah penyajian dan hasil estimasi parameter setiap variabel secara spasial. Statistik deskriptif hasil estimasi parameter model GNNWR disajikan pada Tabel 8.

**Tabel 8.** Statistik deskriptif hasil estimasi variabel model GNNWR

Variabel	GNNWR		
	Min	Mean	Max
Intercept	-9,16	-0,76	8,27
IPM	-7,67	5,60	32,66
RLS	-22,09	1,26	13,23
PPM	-5,20	-0,63	3,00
TPA	-2,98	0,57	5,79

Berdasarkan Tabel 8, Nilai koefisien untuk Intercept bervariasi dari -9,16 hingga 8,27,

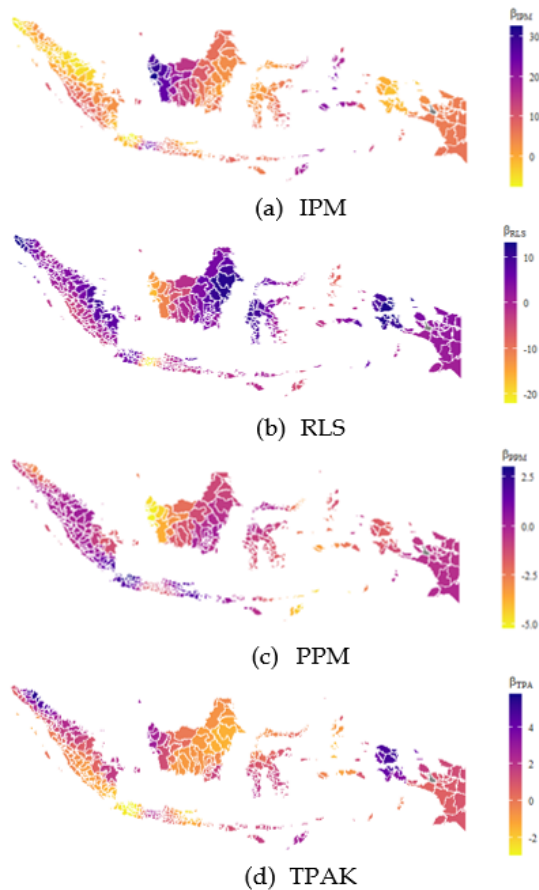
menunjukkan adanya perbedaan kondisi dasar antar wilayah dalam menjelaskan tingkat pengangguran. Variabel IPM menunjukkan nilai koefisien negatif secara umum (*mean* -7,67), yang berarti bahwa peningkatan kualitas hidup cenderung berkorelasi negatif dengan tingkat pengangguran, meskipun terdapat wilayah tertentu dengan pengaruh positif. RLS juga menunjukkan pengaruh negatif yang kuat (*mean* -12,09), mengindikasikan bahwa semakin tinggi rata-rata lama sekolah, semakin rendah tingkat pengangguran di suatu wilayah. Sebaliknya, variabel PPM menunjukkan pengaruh positif (*mean* 5,16), yang sesuai dengan dugaan bahwa tingginya angka kemiskinan berkontribusi pada meningkatnya tingkat pengangguran. Sementara itu, TPA memiliki koefisien negatif dengan nilai rata-rata -0,57, menunjukkan bahwa semakin tinggi partisipasi angkatan kerja, maka tingkat pengangguran cenderung menurun, meskipun besarnya pengaruh bervariasi di tiap daerah. Hasil ini secara keseluruhan mengonfirmasi bahwa pengaruh variabel sosial ekonomi terhadap pengangguran tidak homogen, melainkan sangat bergantung pada karakteristik geografis masing-masing wilayah.

Berdasarkan estimasi koefisien lokal model GNNWR, setiap wilayah memiliki persamaan yang berbeda sesuai karakteristik spasialnya. Sebagai contoh, untuk Kota Makassar diperoleh persamaan sebagaimana ditunjukkan pada Persamaan (23).

$$\begin{aligned} TPT_{\text{Makassar}} = & -6.29 + 8.04(\text{IPM}) \\ & + 6.49(\text{RLS}) - 1.60(\text{PPM}) \\ & + 2.36(\text{TPA}) \end{aligned} \quad (23)$$

Persamaan ini menunjukkan bahwa variabel IPM dan RLS berpengaruh positif terhadap TPT. Artinya, peningkatan kualitas pembangunan manusia dan pendidikan belum sepenuhnya mampu terserap oleh pasar kerja. Hal ini dapat disebabkan karena adanya *mismatch* antara keterampilan tenaga kerja dan kebutuhan industri. Sementara itu PPM justru memiliki pengaruh negatif. Hal ini mengindikasikan bahwa sebagian besar penduduk berpenghasilan rendah justru bekerja di sektor informal, sehingga tidak tercatat sebagai pengangguran terbuka. Adapun TPA berpengaruh positif terhadap TPT di Kota Makassar. Hal ini berarti peningkatan partisipasi tenaga kerja di wilayah ini diikuti oleh peningkatan jumlah pencari kerja yang belum terserap lapangan kerja.

Lebih lanjut, secara spasial variasi koefisien antarwilayah tersebut divisualisasikan pada Gambar 3 berikut.



Gambar 3. Peta Persebaran Estimasi Koefisien

Secara umum, pola pada Gambar 3 menunjukkan bahwa pengaruh variabel-variabel terhadap TPT tidak bersifat seragam di seluruh wilayah. Variabel IPM memiliki pengaruh positif di sebagian besar wilayah timur Indonesia dan Sumatera, menandakan bahwa peningkatan IPM di daerah tersebut berkorelasi dengan kenaikan TPT, kemungkinan karena peningkatan kualitas manusia belum diimbangi dengan ketersediaan lapangan kerja. Sebaliknya, di beberapa wilayah Jawa dan Kalimantan, koefisien IPM bernilai negatif, menunjukkan bahwa peningkatan IPM di sana justru diikuti penurunan TPT. Sementara itu, RLS memperlihatkan nilai negatif kuat di sebagian besar Jawa dan Sumatera bagian barat, mengindikasikan bahwa semakin tinggi tingkat pendidikan rata-rata, semakin rendah tingkat pengangguran di wilayah tersebut.

Adapun variabel PPM dan TPA menunjukkan variasi yang lebih kompleks. Pengaruh PPM

cenderung negatif di sebagian besar wilayah barat Indonesia, mengindikasikan bahwa peningkatan jumlah penduduk miskin justru berasosiasi dengan penurunan TPT, kemungkinan karena penduduk miskin lebih banyak bekerja di sektor informal. Sebaliknya, TPA memiliki koefisien positif tinggi di wilayah timur dan Kalimantan, yang menandakan bahwa peningkatan partisipasi angkatan kerja berpotensi meningkatkan TPT akibat terbatasnya penyerapan tenaga kerja. Pola-pola ini menegaskan adanya nonstasioneritas spasial pada hubungan antarvariabel, di mana pengaruh tiap faktor ekonomi dan sosial terhadap pengangguran sangat bergantung pada karakteristik wilayahnya.

## PENUTUP

### SIMPULAN

Penelitian ini menunjukkan bahwa tingkat pengangguran terbuka (TPT) di Indonesia memiliki pola spasial yang heterogen, dipengaruhi oleh perbedaan kondisi sosial ekonomi di setiap daerah. Model *Geographically Neural Network Weighted Regression* (GNNWR) terbukti mampu menangkap hubungan nonlinier dan variasi spasial antarwilayah dengan lebih baik dibandingkan model OLS maupun GWR. Hasil analisis menunjukkan bahwa variabel Indeks Pembangunan Manusia (IPM), Rata-rata Lama Sekolah (RLS), Persentase Penduduk Miskin (PPM), dan Tingkat Partisipasi Angkatan Kerja (TPA) berpengaruh signifikan terhadap TPT. Selain itu, model GNNWR memberikan performa terbaik dengan nilai  $R^2$  sebesar 0,68 pada data pelatihan dan 0,61 pada data pengujian, AICc terendah (876,33), serta MAPE terkecil (20,01%). Temuan ini menegaskan bahwa integrasi pendekatan spasial dan *neural network* dapat meningkatkan akurasi model prediksi TPT serta memberikan pemahaman yang lebih mendalam terhadap variasi pengangguran antarwilayah di Indonesia.

### SARAN

Berdasarkan hasil penelitian, disarankan agar pengambil kebijakan menggunakan model GNNWR sebagai acuan dalam merancang strategi penurunan TPT. Strategi tersebut dapat disesuaikan dengan karakteristik masing-masing daerah karena terdapat variasi pengaruh antarwilayah. Secara teoretis, penelitian selanjutnya dapat menambahkan

variabel lain yang relevan, seperti infrastruktur, pertumbuhan ekonomi, dan sektor industri. Selain itu, pengembangan model spasial berbasis *neural network* dapat dikembangkan lebih lanjut dengan memperluas analisis ke arah temporal (GTNNWR) untuk menangkap dinamika pengangguran dari waktu ke waktu.

## DAFTAR PUSTAKA

- Akinwande, M. O., Dikko, H. G., & Samson, A. (2015). Variance inflation factor: as a condition for the inclusion of suppressor variable (s) in regression analysis. *Open journal of statistics*, 5(07), 754. <http://dx.doi.org/10.4236/ojs.2015.57075>
- Ardhani, R., Herrhyanto, N., & Agustina, F. (2021). Multiscale geographically weighted regression (MGWR) untuk memodelkan nilai angka buta huruf di Provinsi Sumatera Selatan Tahun 2021. *Jurnal EurekaMatika*, 11(2), 89–98. <https://doi.org/10.17509/jem.v11i2.63140>
- Badan Pusat Statistik. (2025). *Tingkat pengangguran terbuka menurut provinsi* [Tabel statistik]. Diakses dari <https://www.bps.go.id/id/statistics-table/2/NTQzIzI%3D/unemployment-rate-by-province.html>
- Badan Pusat Statistik. (2023). *Keadaan ketenagakerjaan Indonesia Agustus 2023*. Jakarta: Badan Pusat Statistik.
- Chen, Z., Zhang, S., Geng, W., Ding, Y., & Jiang, X. (2022). Use of geographically weighted regression (GWR) to reveal spatially varying relationships between Cd accumulation and soil properties at field scale. *Land*, 11(5), 635. <https://doi.org/10.3390/land11050635>
- Cheng, W., Pu, R., & Wang, B. (2025). AMC: Adaptive Learning Rate Adjustment Based on Model Complexity. *Mathematics*, 13(4), 650. <https://doi.org/10.3390/math13040650>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Comber, A., Brunson, C., Charlton, M., Lu, B., & Harris, P. (2021). *gwverse: A template for a new generic geographically weighted R package*. arXiv preprint arXiv:2109.14542. <https://arxiv.org/abs/2109.14542>
- Dai, Z., Wu, S., Wang, Y., Zhou, H., Zhang, F., Huang, B., & Du, Z. (2022). Geographically convolutional neural network weighted regression: a method for modeling spatially non-stationary relationships based on a global spatial proximity grid. *International journal of Geographical Information Science*, 36(11), 2248–2269. <https://doi.org/10.1080/13658816.2022.2100892>
- Du, Z., Wang, Z., Wu, S., Zhang, F., & Liu, R. (2020). Geographically neural network weighted regression for the accurate estimation of spatial non-stationarity. *International Journal of Geographical Information Science*, 34, 1353–1377. <https://doi.org/10.1080/13658816.2019.1707834>
- Ge, Z., Zhang, N., Zhang, L., Chen, Y., & Wu, S. (2024). A downscaling method of TRMM satellite precipitation based on geographically neural network weighted regression: A case study in Sichuan Province, China. *Atmosphere*, 15(7), 792. <https://doi.org/10.3390/atmos15070792>
- Greene, W. H. (2020). *Econometric analysis* (8th ed.). Upper Saddle River, NJ: Pearson.
- Gujarati, D. N., & Porter, D. C. (2020). *Basic econometrics*. New York, NY: McGraw-Hill.
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2021). *A primer on partial least squares structural equation modeling (PLS-SEM)*. Thousand Oaks, CA: Sage.
- Hwang, J.-S., Lee, S.-S., Gil, J.-W., & Lee, C.-K. (2024). Determination of Optimal Batch Size of Deep Learning Models with Time Series Data. *Sustainability*, 16(14), 5936. <https://doi.org/10.3390/su16145936>
- International Labour Organization. (2022). *World employment and social outlook*. Geneva: International Labour Organization.
- Koç, T. (2022). Bandwidth selection in geographically weighted regression models via information complexity criteria. *Journal of Mathematics*, 2022(1), 8 pages. <https://doi.org/10.1155/2022/1527407>
- Li, X., Han, D., Li, J., & Liu, S. (2024). Surge Phenomenon in Optimal Learning Rate and Batch Size. *NeurIPS* 2024. [https://proceedings.neurips.cc/paper\\_files/paper/2024/file/ef74413c7bf1d915c3e45c72e19a5d32-Paper-Conference.pdf](https://proceedings.neurips.cc/paper_files/paper/2024/file/ef74413c7bf1d915c3e45c72e19a5d32-Paper-Conference.pdf)
- Liu, Y., & Goudie, R. J. B. (2023). Generalized geographically weighted regression model within a modularized Bayesian framework. *Bayesian analysis*, 19(2), 465. <https://arxiv.org/abs/2106.00996>
- Ma, W., Tian, W., Zhou, Q., Miao, Q., & Qianqian. (2021). Analysis on the temporal and spatial heterogeneity of factors affecting urbanization development based on the GTWR model:

- Evidence from the Yangtze River Economic Belt. *Complexity*, 2021(1), 7557346. <https://doi.org/10.1155/2021/7557346>
- Munawaroh, S. R., Endang, Susilo, J. H., & Astuti, H. (2025). Determinants of unemployment rate in Indonesia: A dynamic panel data approach. *Jurnal Ekonomi Pembangunan*, 23(1), 99–112. <https://doi.org/10.29259/jep.v23i1.23310>
- Ni, S., Wang, Z., Wang, Y., Wang, M., Li, S., & Wang, N. (2022). Spatial and Attribute Neural Network Weighted Regression for the Accurate Estimation of Spatial Non-Stationarity. *ISPRS International Journal of Geo-Information*, 11(12), 620. <https://doi.org/10.3390/ijgi11120620>
- Portet S. (2020). A primer on model selection using the Akaike Information Criterion. *Infectious Disease Modelling*, 5, 111–128. <https://doi.org/10.1016/j.idm.2019.12.010>
- Prameswari, Y., Oktaviarina, A., & Ariyanto, D. (2025). Pemodelan spasial penyakit jantung di indonesia menggunakan geographically weighted regression dengan fixed dan adaptive bandwidth. *MATHunesa: Jurnal Ilmiah Matematika*, 13(2).
- Saputri, M. N., Sifriyani, S., & Wasono, W. (2023). Application of nonparametric geographically weighted regression method on open unemployment rate data in Indonesia. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 17(4), 2071–2080. <https://doi.org/10.30598/barekengvol17iss4p2071-2080>
- Suciptawati, N., Sugiantari, N. I., & Susilawati, M. (2023). Penerapan metode geographically weighted regression (GWR) pada kasus penyakit COVID-19 di Provinsi Bali. *E-Jurnal Matematika*, 12(1), 9–18. <https://doi.org/10.24843/MTK.2023.v12.i01.p393>
- Wang, S., Gao, K., Zhang, L., Yu, B., & Easa, S. M. (2024). Geographically weighted machine learning for modeling spatial heterogeneity in traffic crash frequency and determinants in US. *Accident Analysis & Prevention*, 199, 107528. <https://doi.org/10.1016/j.aap.2024.107528>
- Wang, Z., Wang, Y., & Wu, S. (2022). House price valuation model based on geographically neural network weighted regression: The case study of Shenzhen, China. *ISPRS International Journal of Geo-Information*, 11, 450. <https://doi.org/10.3390/ijgi11080450>
- Wooldridge, J. M. (2020). *Introductory econometrics: A modern approach* (7th ed.). Boston, MA: Cengage Learning.
- World Bank. (2021). *World development report 2021: Data for better lives*. Washington, DC: World Bank.
- Yin, Z., Ding, J., Liu, Y., Wang, R., Wang, Y., Chen, Y., Qi, J., Wu, S., & Du, Z. (2024). GNNWR: an open-source package of spatiotemporal intelligent regression methods for modeling spatial and temporal nonstationarity. *Geoscientific Model Development Discussions*, 2024, 1–22. <https://doi.org/10.5194/gmd-17-8455-2024>.
- Zhou, Y., Wu, J., Liu, R., & Yu, Z. (2025). Spatial economic correlations via geographically weighted neural network regression with a new dataset. *Applied and Computational Engineering*, 132, 55–69. <https://doi.org/10.54254/2755-2721/2024.20531>