

SPATIAL MODELING OF HDI DISPARITIES IN INDONESIA IN 2024 USING MULTISCALE GEOGRAPHICALLY WEIGHTED QUANTILE REGRESSION (MGWQR)*

PEMODELAN SPASIAL DISPARITAS IPM DI INDONESIA TAHUN 2024 MENGGUNAKAN *MULTISCALE GEOGRAPHICALLY WEIGHTED QUANTILE REGRESSION (MGWQR)*

Kartika Rizkia Zuhrah¹, Yekti Widyaningsih²

^{1,2}Department of Mathematics, Universitas Indonesia, Indonesia
‡kartikazuhrah@gmail.com

Copyright © 2026 Kartika Rizkia Zuhrah and Yekti Widyaningsih. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

HDI measures developmental success across living standards, education, and health dimensions. In 2024, Indonesia's regency-level HDI exhibited significant spatial heterogeneity and asymmetrical distribution with outliers, rendering conventional mean-based estimations insufficient. As an applicative contribution, this study models HDI disparities across 514 districts by applying the Multiscale Geographically Weighted Quantile Regression (MGWQR) method to accommodate spatial variations and multiscale predictor effects. Secondary data from Statistics Indonesia (BPS) and the Indonesian Geospatial Information Agency (BIG) are analyzed at 0.1, 0.5, and 0.9 quantiles, utilizing predictors including poverty rate, GRDP, mean years of schooling (MYS), births without public facilities, and undernourishment. Results indicate that the MGWQR (bisquare kernel) emerges as the optimal model, achieving a pseudo R-squared of 91% and reducing the mean quantile loss by 35.6%. MYS is the most stable positive predictor, while GRDP primarily drives low-HDI regions. Conversely, poverty acts as the main limiting predictor in the high-extreme quantile (0.9). This reveals a distinct spatial typology, where low-HDI areas depend on all socioeconomic dimensions, whereas advanced regions are no longer constrained by health access or undernourishment. This research underscores the necessity of multiscale modeling for precision policymaking, providing a robust framework for regional developmental

strategies. Future research should integrate temporal dynamics to capture long-term spatial shifts.

Keywords: Multiscale, Outliers, Quantile Regression, Spatial Heterogeneity, Spatial Scale.

Abstrak

Indeks Pembangunan Manusia (IPM) merupakan indikator penting untuk mengukur keberhasilan pembangunan melalui dimensi standar hidup layak, pendidikan, dan kesehatan. IPM kabupaten/kota di Indonesia tahun 2024 menunjukkan heterogenitas spasial dengan sebaran asimetris (*left-skewed*) dan keberadaan pencilan. Pendekatan estimasi berbasis rata-rata memiliki keterbatasan dalam menangkap dinamika hubungan antarvariabel pada nilai ekstrem, sehingga diperlukan metode yang lebih *robust*. Sebagai kontribusi aplikatif, penelitian ini bertujuan untuk memodelkan disparitas IPM di 514 kabupaten/kota dengan menerapkan metode *Multiscale Geographically Weighted Quantile Regression* (MGWQR) untuk mengatasi variasi spasial, distribusi asimetris, dan perbedaan skala pengaruh (*bandwidth*) antarvariabel. Penelitian ini menggunakan data sekunder dari BPS dan BIG, yang dianalisis pada kuantil 0,1; 0,5; dan 0,9 dengan variabel prediktor mencakup persentase penduduk miskin (PPM), PDRB (Ln_PDRB), rata-rata lama sekolah (RLS), proporsi persalinan tanpa fasilitas kesehatan (PTF), serta prevalensi ketidakcukupan konsumsi pangan (PKKP). Analisis difokuskan pada kuantil 0,1 dan 0,9 sebagai representasi wilayah dengan capaian IPM ekstrem rendah dan ekstrem tinggi, serta kuantil 0,5 sebagai kondisi median. Hasil penelitian menunjukkan bahwa MGWQR dengan *kernel bisquare* merupakan model terbaik dengan nilai *Pseudo R-squared* mencapai 91% dan mampu mereduksi *Mean Quantile Loss* hingga 35,6% relatif terhadap model QR. Hasil analisis spasial multiskala menunjukkan variabel RLS sebagai prediktor positif paling stabil, sedangkan Ln_PDRB memberikan efek dorongan terbesar di wilayah dengan IPM rendah. Sebaliknya, kemiskinan (PPM) menjadi variabel penghambat paling sensitif di kuantil 0,9. Tipologi spasial yang terbentuk menunjukkan daerah IPM rendah sangat dipengaruhi seluruh dimensi pembangunan, sementara wilayah IPM tinggi tidak lagi dipengaruhi secara signifikan oleh aksesibilitas fasilitas kesehatan (PTF) dan ketahanan pangan (PKKP).

Kata Kunci: Heterogenitas Spasial, Multiskala, Pencilan, Regresi Kuantil, Skala Spasial.

1. Pendahuluan

Indeks Pembangunan Manusia (IPM) oleh *United Nations Development Programme* (UNDP) tahun 1990 mengukur keberhasilan pembangunan manusia melalui dimensi standar hidup layak, pendidikan, dan kesehatan (Purwaningsih *et al.*, 2023). Pada tahun 2024, capaian IPM tingkat kabupaten/kota di Indonesia menunjukkan keragaman spasial yang tinggi dan sebaran asimetris. Disparitas ini terlihat jelas pada kesenjangan antarwilayah, misalnya antara Kota Medan dan Kabupaten Nias Selatan

(Satyahadewi *et al.*, 2023). Karena estimasi statistik berbasis rata-rata sering kali gagal menangkap dinamika pada kondisi ekstrem atau keberadaan pencilan tersebut, pendekatan regresi kuantil menjadi solusi yang lebih relevan (Chen *et al.*, 2012)

Dalam konteks spasial, model *Geographically Weighted Quantile Regression* (GWQR) mampu mengakomodasi heterogenitas spasial, namun terbatas oleh asumsi skala spasial yang seragam (Fotheringham *et al.*, 2017). Kenyataannya, setiap prediktor IPM memiliki jangkauan pengaruh geografis yang bervariasi. Misalnya, PDRB memiliki efek limpahan (*spillover*) berskala regional (Yulianti *et al.*, 2021), sementara rata-rata lama sekolah (RLS) bersifat lebih sempit dan lokal (Mala & Hidayat, 2023). Oleh karena itu, penelitian ini menerapkan metode *Multiscale Geographically Weighted Quantile Regression* (MGWQR) yang mampu mengakomodasi variasi spasial, distribusi asimetris, dan perbedaan skala pengaruh prediktor secara simultan (Elkady *et al.*, 2025) sebagai salah satu aplikasi pertama metode MGWQR dalam konteks analisis spasial di Indonesia.

Analisis difokuskan pada kuantil ekstrem (0,1 dan 0,9) untuk merepresentasikan daerah dengan ketertinggalan pembangunan dan pusat pertumbuhan, serta median (0,5) sebagai kondisi dasar yang merujuk pada kerangka simulasi dasar MGWQR oleh Elkady *et al.* (2025). Terdapat lima prediktor IPM yang digunakan, yaitu tingkat kemiskinan dan PDRB (dimensi standar hidup layak), rata-rata lama sekolah (dimensi pendidikan), serta persalinan tanpa fasilitas kesehatan dan ketidakcukupan konsumsi pangan (dimensi kesehatan). Kinerja MGWQR selanjutnya dievaluasi terhadap model regresi kuantil global (QR) dan GWQR melalui *Mean Quantile Loss* dan *Pseudo R-squared*, serta plot sebaran sisaan terhadap nilai prediksi model. Model terbaik akan digunakan untuk mengidentifikasi prediktor yang signifikan dalam menjelaskan IPM dengan pendekatan spasial, sehingga diperoleh pemahaman yang mendalam dan realistis mengenai disparitas pembangunan manusia tingkat kabupaten/kota di Indonesia tahun 2024.

2. Metodologi

2.1 Bahan dan Data

Data atribut yang digunakan merupakan data sekunder dari tabel statistik pada situs resmi Badan Pusat Statistik (BPS) Indonesia, sedangkan data batas wilayah (*shapefile*) diperoleh dari situs resmi Badan Informasi Geospasial (BIG). Data penelitian bersifat *cross-section* yang berfokus pada tahun 2024 dengan total 514 unit pengamatan.

Penelitian ini menggunakan lima variabel prediktor tingkat kabupaten/kota. Pertama, PDRB Atas Dasar Harga Konstan (Ln_PDRB,

miliar rupiah), yaitu nilai tambah bruto produk seluruh sektor ekonomi berdasarkan harga tahun 2010. Kedua, Persentase Penduduk Miskin (PPM, %) yang mengukur proporsi penduduk dengan rata-rata pengeluaran di bawah garis kemiskinan. Ketiga, Rata-Rata Lama Sekolah (RLS, tahun) pada penduduk usia 25 tahun ke atas. Keempat, Proporsi Persalinan Tanpa Fasilitas Kesehatan (PTF, proporsi/desimal) pada perempuan usia 15-49 tahun dalam dua tahun terakhir, serta Prevalensi Ketidacukupan Konsumsi Pangan (PKKP, %) yang merepresentasikan penduduk dengan asupan energi harian di bawah ambang minimum 700-1000 kkal.

Data atribut BPS dan data spasial batas wilayah BIG disinkronisasi berdasarkan nama unit administrasi kabupaten/kota ke dalam satu det data yang bersih dari *missing values* dan duplikasi data. Variabel PDRB ditransformasi menjadi logaritma natural ($\ln$) untuk mengatasi kemencengan distribusi (*right-skewed*) dan menstabilkan variansi antarprediktor. Kemudian sistem koordinat diproyeksikan ke standar global WGS 84 (EPSG: 4326) untuk menjamin akurasi perhitungan jarak spasial berskala nasional.

2.2 Metode Penelitian

Tahapan analisis data dalam penelitian ini dilakukan dengan langkah-langkah sebagai berikut.

a. Eksplorasi dan Visualisasi Data

Tahap ini dimulai dari eksplorasi data untuk mengidentifikasi karakteristik, pola dan struktur data sebelum dilakukan pemodelan. Analisis distribusi dan visualisasi variabel respons dilakukan melalui peta sebaran spasial variabel respons. Kemudian dilanjutkan dengan identifikasi pencilan melalui visualisasi *boxplot* dengan metode *Interquartile Range* (IQR).

b. Pengujian Asumsi dan Pemeriksaan Diagnostik Model

- Uji Asumsi Nonmultikolinearitas
Multikolinearitas diuji secara global melalui *Variance Inflation Factor* (VIF) dan secara lokal menggunakan *Pseudo-Local VIF* untuk mengantisipasi peningkatan variansi akibat kolinearitas spasial pada MGWQR. Ambang batas stabilitas estimasi parameter ditetapkan pada nilai $VIF > 10$.
- Identifikasi Pengamatan Berpengaruh (*Influential Observations*)
Pengamatan berpengaruh pada estimasi model diidentifikasi melalui metode *Cook's Distance* (Cook, 1977) yang mengintegrasikan *studentized residual squared* dan *leverage ratio*, dengan ambang batas sebesar $4/n$.
- Uji Heterogenitas Spasial
Keberadaan heterogenitas spasial diuji melalui *Modified*

Breusch-Pagan yang lebih *robust* terhadap pencilan (Abdul-Hameed & Matanmi, 2021). Signifikansi heterogenitas spasial tercapai jika statistik uji Φ^* melampaui nilai kritis *Chi-square* pada tingkat signifikansi α .

- c. Pembentukan Matriks Pembobot Spasial dan Optimasi *Bandwidth*
 Jarak spasial antarwilayah dihitung melalui *Great Circle Distance* dengan formula Haversine (Azdy & Darnis, 2020), dengan titik koordinat terlebih dahulu dikonversi ke radian. Pembobotan spasial menggunakan *kernel bisquare* pada Persamaan (1) dengan skema *bandwidth* adaptif berbasis tetangga terdekat (*k-Nearest Neighbors*). Pendekatan adaptif ini dipilih untuk mengakomodasi variasi densitas wilayah antarpulau di Indonesia, sehingga menjaga kestabilan estimasi model di setiap tingkat densitas wilayah (Paramita *et al.*, 2023).

$$K_B(d_{ij}) = \begin{cases} \left[1 - \left(\frac{d_{ij}}{b}\right)^2\right]^2, & \text{jika } d_{ij} < b \\ 0, & \text{jika } d_{ij} \geq b \end{cases} \quad (1)$$

Keterangan:

$K(d_{ij})$: fungsi pembobot spasial.

d_{ij} : *Great Circle Distance* titik pengamatan ke- i dan j .

b : nilai *bandwidth* optimum.

Kriteria pemilihan *bandwidth* optimum menggunakan *Leave-One-Out Cross-Validation* (LOOCV) yang dinilai lebih layak (*feasible*) pada pendekatan berbasis kuantil (Chen *et al.*, 2012; Elkady *et al.*, 2025).

- d. Pemodelan Regresi Kuantil Global (QR)

Regresi kuantil digunakan untuk memodelkan hubungan antara variabel prediktor dan berbagai titik distribusi bersyarat (*conditional quantiles*) dari variabel respons (Koenker & Bassett Jr., 1978). Secara matematis, model regresi kuantil dituliskan sebagai berikut.

$$q_\tau = \beta_{0\tau} + \sum_{k=1}^m \beta_{k\tau} x_k + \varepsilon_\tau \quad (2)$$

dengan q_τ merupakan nilai kuantil ke- τ dari variabel respons, $\beta_{0\tau}$ adalah intersep, dan $\beta_{k\tau}$ menunjukkan koefisien untuk variabel prediktor ke- k (x_k) dari total m prediktor. Variabel ε_τ merepresentasikan galat dengan asumsi $P(\varepsilon_\tau \leq 0) = \tau$, yang menjamin garis regresi bergeser secara fleksibel hingga terdapat τ persen data yang berada di bawah garis tersebut.

Proses pendugaan parameter dilakukan dengan meminimalkan fungsi kerugian kuantil asimetris (ρ_τ) yang diberi bobot sebesar τ .

$$\begin{aligned}
\hat{\beta} &= \arg \min_{\beta \in \mathbb{R}^p} \sum_{i=1}^n \rho_{\tau}(y_i - \mathbf{X}_i' \beta) \\
&= \arg \min_{\beta \in \mathbb{R}^p} \left(\tau \sum_{y_i \geq \mathbf{X}_i' \beta} |y_i - \mathbf{X}_i' \beta| \right. \\
&\quad \left. + (1 - \tau) \sum_{y_i < \mathbf{X}_i' \beta} |y_i - \mathbf{X}_i' \beta| \right)
\end{aligned} \tag{3}$$

Dengan β merupakan vektor parameter berukuran $p \times 1$ dan p menunjukkan jumlah parameter termasuk intersep.

- e. *Pemodelan Geographically Weighted Quantile Regression (GWQR)*
Model GWQR memperluas regresi kuantil global dengan mengakomodasi atribut spasial melalui penambahan titik koordinat (u_i, v_i) pada setiap lokasi pengamatan ke- i .

$$q_{\tau}(\mathbf{x}_i, u_i, v_i) = \beta_{0\tau}(u_i, v_i) + \sum_{k=1}^m x_{ik} \beta_{k\tau}(u_i, v_i) + \varepsilon_{i\tau} \tag{4}$$

Berbeda dengan model global, estimasi intersep $\beta_{0\tau}(u_i, v_i)$ dan koefisien prediktor $\beta_{k\tau}(u_i, v_i)$ pada GWQR bersifat lokal untuk setiap lokasi i . Komponen $\varepsilon_{i\tau}$ merupakan galat dengan asumsi kuantil ke- τ dari galat tersebut adalah nol (Elkady, 2025).

Pendugaan parameter GWQR memodifikasi fungsi kerugian kuantil dengan menambahkan pembobot spasial w_i .

$$\hat{\beta} = \arg \min_{\beta \in \mathbb{R}^p} \sum_{i=1}^n \rho_{\tau}(y_i - \mathbf{X}_i' \beta) w_i \tag{5}$$

Karena fungsi ρ_{τ} tidak terdiferensialkan pada titik nol (*no closed-form solution*), proses estimasi koefisien diselesaikan secara efisien menggunakan algoritma Barrodale-Roberts (BR) (Chen et al., 2012).

- f. *Pemodelan Multiscale Geographically Weighted Quantile Regression (MGWQR)*

MGWQR mengintegrasikan regresi kuantil dengan pembobotan spasial multiskala melalui struktur *Quantile Additive Model* (Elkady et al., 2025) dengan memecah hubungan kompleks menjadi penjumlahan komponen aditif fungsi sederhana.

$$\begin{aligned}
q_{\tau}(\mathbf{x}_i, u_i, v_i) &= \beta_{b_0\tau}(u_i, v_i) + \sum_{k=1}^m \beta_{b_k\tau}(u_i, v_i) x_{ik} + \varepsilon_{i\tau} \\
&= \sum_{k=0}^p f_{k\tau}(x_{ik}, u_i, v_i) + \varepsilon_{i\tau}
\end{aligned} \tag{6}$$

Berbeda dengan model spasial berskala tunggal, setiap komponen aditif $f_{k\tau}$ diestimasi menggunakan koefisien regresi lokal $\beta_{b_k\tau}(u_i, v_i)$ yang memiliki skala *bandwidth* optimum spesifik (b_k) untuk setiap prediktor ke- k .

Pendugaan parameter MGWQR dilakukan melalui algoritma

backfitting iteratif. Setelah menetapkan taksiran awal dari GWQR berskala tunggal, komponen aditif setiap prediktor ($\hat{f}_{k\tau}$) diperbarui secara berurutan melalui isolasi residu parsial. Residu parsial tersebut kemudian diregresikan secara univariat menggunakan GWQR untuk mengoptimasi *bandwidth* dan memperbarui koefisien estimasi. Siklus ini terus diulang hingga tercapai konvergensi, yaitu ketika nilai *Score of Change* (SOC) dari total *quantile loss* berada di bawah ambang toleransi 0,001.

g. Evaluasi Kinerja Model dan Analisis Sisaan

Kinerja model dievaluasi melalui *Mean Quantile Loss* sebagai nilai rata-rata jumlah *quantile loss* model dan *Pseudo R-squared* ($R^1(\tau)$).

$$R^1(\tau) = 1 - \frac{\sum_{i=1}^n \rho_{\tau}(y_i - x_i' \hat{\beta}_{\tau})}{\sum_{i=1}^n \rho_{\tau}(y_i - \hat{\beta}_{0\tau})} \quad (7)$$

Metrik ini membandingkan total simpangan absolut dari model lengkap (pembilang) terhadap model yang hanya memuat intersep (penyebut). Selanjutnya, sebaran sisaan divisualisasikan terhadap nilai prediksi yang disesuaikan dengan kelompok fokusnya untuk melihat keberhasilan model dalam menangani heterogenitas spasial. Untuk mengukur kinerja *out-of-sample* dan mencegah *overfitting* spasial pada 514 unit pengamatan, pengujian eksternal diterapkan melalui *5-Fold Spatial Cross-Validation* (Lee et al., 2025). Validasi silang ini diimplementasikan melalui pendekatan *fixed-bandwidth approximation* untuk menangani tingginya beban komputasi, dengan *bandwidth* optimum dipertahankan konstan.

h. Pengujian Signifikansi Parameter Lokal


Karena model MGWQR tidak memiliki distribusi asimtotik analitik yang *well-established*, signifikansi parameter lokal diuji menggunakan *pairs Bootstrap*. Estimasi diulang sebanyak 500 iterasi untuk membentuk distribusi *Bootstrap* lokal pada setiap lokasi pengamatan ke- i dan kuantil ke- τ . Evaluasi signifikansi didasarkan pada *Bootstrap Standard Error-based t-test*. Hasil pengujian ini divisualisasikan dalam bentuk *faceted map* untuk memperjelas sebaran spasial wilayah yang signifikan pada setiap tingkat kuantil.

3. Hasil dan Pembahasan

3.1 Eksplorasi Data dan Analisis Pola Spasial

Secara statistik, distribusi capaian IPM kabupaten/kota di Indonesia tahun 2024 membentuk pola asimetris menjulur ke kiri (*left-skewed*). Hal ini mengindikasikan terdapat ketertinggalan ekstrem di beberapa wilayah. Identifikasi melalui metode *Interquartile Range* (IQR) mendeteksi 10 pencilan atas (mayoritas di Pulau Jawa) dan 18 pencilan bawah yang didominasi wilayah Papua. Pola disparitas spasial ini divisualisasikan

melalui peta sebaran pada Gambar 1.



Gambar 1: Peta sebaran capaian IPM kabupaten/kota di Indonesia tahun 2024

Lebih lanjut, diagnostik Cook's *Distance* mendeteksi 29 pengamatan berpengaruh, dengan 13 di antaranya beririsan dengan pencilan IQR. Secara geografis, kelompok ini mencakup 10 wilayah pencilan bawah ekstrem (seperti Kabupaten Nduga, Dogiyai, dan Puncak Jaya) serta tiga wilayah dengan capaian IPM sangat tinggi (Kota Yogyakarta, Salatiga, dan Kabupaten Sleman). Untuk pengujian asumsi nonmultikolinearitas secara global, nilai VIF seluruh prediktor berada di bawah 10 (PPM = 2,21; PKKP = 1,87; PTF = 1,65; Ln_PDRB = 1,54; RLS = 1,52), sehingga tidak terdapat masalah multikolinearitas global. Selanjutnya, hasil uji heterogenitas spasial menunjukkan statistik uji MBP sebesar 76,20 ($> \chi^2 = 11,07$), sehingga H_0 (tidak terdapat heterogenitas spasial) ditolak. Temuan ini menjadi landasan empiris penggunaan model dengan pendekatan spasial untuk mengakomodasi variasi spasial antarwilayah.

3.2 Estimasi Parameter Model

Evaluasi kinerja model pada kuantil $\tau = 0,1; 0,5; 0,9$ menunjukkan bahwa MGWQR (*kernel bisquare*) secara konsisten lebih unggul dari QR dan GWQR (Tabel 1). Temuan ini mengonfirmasi pendekatan multiskala pada variabel prediktor mampu menangkap kompleksitas data secara lebih akurat.

Tabel 1: Perbandingan kinerja model QR, GWQR, dan MGWQR


Kuantil	Model	Mean Quantile Loss	Pseudo R-squared
0.1	QR	0.32	0.85
	GWQR	0.24	0.89
	MGWQR	0.22	0.90
0.5	QR	0.72	0.67
	GWQR	0.50	0.77
	MGWQR	0.46	0.79
0.9	QR	0.31	0.87
	GWQR	0.24	0.90
	MGWQR	0.21	0.91

Untuk memvalidasi bahwa model tidak mengalami *overfitting* spasial, evaluasi prediktif (*out-of-sample*) dilakukan melalui *5-Fold Cross Validation* (Tabel 2). Hasilnya, MGWQR menghasilkan *Mean Quantile Loss* terendah di seluruh tingkat kuantil dibandingkan model QR maupun GWQR. Konsistensi ini menegaskan bahwa pendekatan multiskala MGWQR tidak sekadar merekam kebisingan (*noise*) data latih, melainkan secara akurat menangkap sinyal heterogenitas spasial yang esensial, sehingga menghasilkan estimasi prediksi yang *robust* untuk wilayah tidak teramati.

Tabel 2: Perbandingan *Mean Quantile Loss* model QR, GWQR, dan MGWQR melalui *5-Fold Cross Validation*.

Kuantil	<i>Mean Quantile Loss</i>		
	QR	GWQR	MGWQR
0.1	35.33	31.83	31.43
0.5	75.68	65.06	62.24
0.9	32.59	30.32	29.27

Selain evaluasi metrik kinerja, visualisasi plot sebaran sisaan terhadap nilai prediksi pada Gambar 2 juga mengonfirmasi keunggulan model MGWQR. Dengan mengelompokkan pengamatan berdasarkan sisaan mutlak minimum, terlihat bahwa sebaran sisaan model MGWQR terdistribusi jauh lebih padat di sekitar garis nol dibandingkan model lainnya pada seluruh tingkat kuantil.



Gambar 2: Sebaran Sisaan terhadap Nilai Prediksi Model


Perbandingan *bandwidth* optimum (Tabel 3) menunjukkan keunggulan pendekatan multiskala pada MGWQR. Pada wilayah ber-IPM rendah (kuantil 0,1), RLS (31) dan Ln_PDRB (45) beroperasi sangat lokal, yang menunjukkan wilayah IPM rendah umumnya berada di daerah dengan konektivitas infrastruktur yang minim. Sebaliknya, skala pengaruh PKKPP (112) dan PPM (144) lebih regional. Hal ini mengindikasikan isu pangan dan kemiskinan sebagai masalah sistemik lintas wilayah akibat rantai pasok logistik yang terpusat (Estiningtyas *et al.*, 2021). Implikasinya, intervensi pendidikan dan ekonomi di daerah tertinggal menuntut kebijakan hiperlokal dan spesifik, sedangkan isu ketahanan pangan dan kemiskinan memerlukan koordinasi regional.

Tabel 3: Perbandingan *bandwidth* optimum untuk setiap variabel prediktor.


Kuantil	Model	<i>Bandwidth</i> Optimum (<i>Nearest Neighbors</i>)				
		PPM	Ln_PDRB	RLS	PKKP	PTF
0.1	GWQR			174		
	MGWQR	144	45	31	112	118
0.5	GWQR			96		
	MGWQR	76	39	57	189	57
0.9	GWQR			225		
	MGWQR	145	115	109	237	102

Pada kondisi median (kuantil 0,5), penyusutan *bandwidth* PPM (76) dan PTF (57) dipicu oleh hambatan sosiokultural dan topografi mikro di tingkat daerah (Nasir *et al.*, 2020). Sementara itu, pada wilayah dengan capaian IPM tinggi (kuantil 0,9), seluruh prediktor menunjukkan skala spasial yang meluas (global), seperti Ln_PDRB (115), RLS (109), hingga PKKPP (237). Tingginya konektivitas dan aglomerasi di pusat pertumbuhan menciptakan homogenitas spasial dengan efek limpahan (*spillover*) yang kuat antarwilayah (Yulianti *et al.*, 2021).


Hasil uji signifikansi parameter melalui *Bootstrap* (Gambar 3) menunjukkan dinamika spasial antarkuantil. Pada wilayah ber-IPM rendah ($\tau = 0,1$), PTF tidak signifikan di kawasan timur Indonesia (seperti klaster Papua, Maluku, dan Nusa Tenggara) serta sebagian Jawa Timur. Hal ini mengindikasikan keterbatasan infrastruktur atau preferensi melahirkan di luar faskes sebagai fenomena sistemik akibat isolasi geografis. Di kuantil yang sama, ketidaksignifikanan PPM di Sumatera bagian selatan, Banten, DKI Jakarta, dan Bali menandakan bahwa capaian IPM lebih dipicu oleh isu spesifik di luar angka kemiskinan absolut.



a. Kuantil 0,1



b. Kuantil 0,5



c. Kuantil 0,9

Gambar 3: Kelompok Wilayah Berdasarkan Kombinasi Prediktor Signifikan

Pada kondisi median ($\tau = 0,5$), PKKP dan PPM mulai kehilangan signifikansi di hampir seluruh kawasan barat dan tengah Indonesia (khususnya aglomerasi Jawa-Bali). Sebaliknya, kawasan timur Indonesia (khususnya pedalaman Papua) menunjukkan kerentanan multisektoral yang tinggi karena seluruh prediktor signifikan secara simultan. Pada kuantil ekstrem atas ($\tau = 0,9$) yang merepresentasikan wilayah ber-IPM tinggi, peta signifikansi menunjukkan bahwa di kawasan barat Indonesia (meliputi aglomerasi DKI Jakarta, Jawa Barat, Jawa Tengah, hingga pesisir timur Sumatera), prediktor PTF justru menjadi tidak signifikan. Sementara itu, di kawasan timur Indonesia (Sulawesi, Maluku, Papua, dan Nusa Tenggara), prediktor PKKP menjadi tidak signifikan. Bagi pusat-pusat pertumbuhan urban di kawasan timur tersebut, pemenuhan akses pangan dasar telah terlampaui sehingga tidak lagi menjadi diferensiator capaian

IPM. Secara keseluruhan, distribusi spasial yang sangat bervariasi antarkuantil dan antarpanel ini menegaskan bahwa prediktor pembangunan manusia di Indonesia tidak berdampak secara seragam dan linear. Temuan ini menunjukkan pentingnya perumusan intervensi kebijakan yang presisi dan disesuaikan dengan karakteristik geografi serta tingkat capaian wilayahnya.

Untuk evaluasi lanjutan terhadap kestabilan model di tingkat lokal, dilakukan diagnostik multikolinearitas spasial melalui *Pseudo-Local* VIF pada seluruh unit pengamatan. Hasil pengujian menunjukkan bahwa pada kuantil 0,5 dan 0,9, seluruh nilai VIF lokal berada di bawah ambang batas 10. Pada kuantil 0,1, nilai maksimum *Pseudo-Local* VIF mencapai 11,11 dengan tiga daerah yang nilainya melebihi 10 secara spesifik pada variabel RLS, yaitu Kabupaten Bangkalan, Bojonegoro, dan Gresik. Karena proporsi wilayah yang terindikasi multikolinearitas lokal sangat kecil, temuan ini secara empiris menegaskan bahwa estimasi koefisien spasial pada model MGWQR (*kernel bisquare*) tetap valid dan stabil secara keseluruhan.

4. Simpulan dan Saran

Model MGWQR (*kernel bisquare*) terbukti sebagai pendekatan terbaik untuk memetakan disparitas spasial IPM di Indonesia tahun 2024. Secara spasial, RLS dan PDRB menjadi pendorong utama di kawasan tertinggal, sementara kemiskinan menjadi penghambat utama di wilayah maju. Temuan ini mengonfirmasi tipologi pembangunan yang dinamis, yaitu wilayah ber-IPM rendah di luar Jawa masih sangat bergantung pada seluruh indikator pembangunan, sedangkan wilayah maju di kawasan barat telah melepaskan ketergantungan pada akses fasilitas kesehatan dan ketahanan pangan.

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan analitis. Pertama, sifat iteratif dari algoritma *backfitting* memunculkan kompleksitas komputasi yang tinggi. Kedua, penaksiran spasial di wilayah dengan kepadatan pengamatan rendah (*sparse regions*) seperti Papua memiliki kerentanan teoritis terhadap ketidakstabilan koefisien lokal akibat sangat melebarnya jarak ketetanggaan. Ketiga, studi ini belum mengeksplorasi kondisi kuantil lainnya (seperti 0,25 dan 0,75) yang dapat merepresentasikan transisi pembangunan. Oleh karena itu, penelitian selanjutnya disarankan untuk menerapkan teknik komputasi paralel dan melakukan analisis sensitivitas pada rentang kuantil yang lebih rapat untuk memetakan transisi pengaruh spasial dari prediktor IPM secara lebih komprehensif.

Daftar Pustaka

Abdul-Hameed, B., & Matanmi, O. G. (2021). A Modified Breusch-Pagan Test for Detecting Heteroscedasticity in the Presence of Outliers. *Pure and Applied Mathematics Journal*, 10(6), 139–149.

<https://doi.org/10.11648/j.pamj.20211006.13>

Abdulrahman Taresh, A., Sari, D. W., & Purwono, R. (2021). Analysis of the relationship between income inequality and social variables: Evidence from Indonesia. *Economics and Sociology*, 14(1), 103–119. <https://doi.org/10.14254/2071-789X.2021/14-1/7>

Al-Guraibawi, M., Raheem, S. H., & Mohammed, B. K. (2025). A NEW MODIFIED ROBUST MAHALANOBIS DISTANCE BASED ON MRCD TO DIAGNOSE HIGH LEVERAGE POINTS. *Pakistan Journal of Statistics*, 41(1), 35–50. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85211182150&partnerID=40&md5=f905460842d89e6ebf07d9952b904ec7>

Alfa Syukrilla, W., Andriyana, Y., & Verhasselt, A. (2023). Geographically Weighted Quantile Regression for Assessing the Spatial Variations of the High-Risk Diarrhea on Children Under Five in Bandung, Indonesia. *International Journal of Application on Sciences, Technology and Engineering*, 1(2), 508–522. <https://doi.org/10.24912/ijaste.v1.i2.508-522>

Azdy, R. A., & Darnis, F. (2020). Use of Haversine Formula in Finding Distance Between Temporary Shelter and Waste End Processing Sites. *Journal of Physics: Conference Series*, 1–7. <https://doi.org/10.1088/1742-6596/1500/1/012104>

Badan Pusat Statistik. (2024). Indeks Pembangunan Manusia Indonesia 2024. *Badan Pusat Statistik*, 19(73), 1–195. <https://www.bps.go.id/id/publication/2025/05/15/dd9a3ce7dfae1c733e46338f/ind-eks-pembangunan-manusia-2024.html>

Chen, V. Y. J., Deng, W. S., Yang, T. C., & Matthews, S. A. (2012). Geographically Weighted Quantile Regression (GWQR): An Application to U.S. Mortality Data. *Geographical Analysis*, 44(2), 134–150. <https://doi.org/10.1111/j.1538-4632.2012.00841.x>

Cook, R. D. (1977). Detection of Influential Observation in Linear Regression. *Technometrics*, 19(1), 15–18. <https://doi.org/10.1080/00401706.1977.10489493>

Elkady, A. H., Abdrabou, A. S., & Elayouty, A. (2025). Multiscale geographically weighted quantile regression. *Spatial Economic Analysis*, 1772, 1–24. <https://doi.org/10.1080/17421772.2024.2445506>

Estiningtyas, W., Mulyani, A., Sumaryanto, & B, K. (2021). Assessing the vulnerability of food farming system to support climate change adaptation : A case study in Java , Indonesia. *IOP Conference Series: Earth and Environmental Science PAPER*, 1–10. <https://doi.org/10.1088/1755-1315/648/1/012093>

- Fotheringham, A. S., Yang, W., & Kang, W. (2017). Multiscale Geographically Weighted Regression (MGWR). *Annals of the American Association of Geographers*, 107(6), 1247–1265.
- Herbiansyah, T., Yahya, I., Baharuddin, Agusrawati, Ruslan, & Laome, L. (2022). Pemodelan Produk Domestik Regional Bruto di Indonesia dengan Geographically Weighted Regression. *Prosiding Seminar Nasional Sains Dan Terapan (Sinta) Vi*, 6(April), 23–33. <https://ejournal.unsrat.ac.id/v3/index.php/sinta6/article/view/41868>
- Koenker, R., & Bassett Jr., G. (1978). Regression Quantiles. *Econometrica*, 46(1), 33–50. <https://share.google/efQlvkOmYrAsQRJ2P>
- Lee, Y., Kim, C., Jeong, H., Kim, D., Lee, B., Park, T., Kim, S., Jeon, D., Ahn, J., Lee, J., Cha, Y., & Lee, S. (2025). Geographically weighted machine learning for predicting the spatial distribution of groundwater nitrate nitrogen (NO₃-N) concentration. *Journal of Hydrology: Regional Studies*, 62, 102867. <https://doi.org/10.1016/j.ejrh.2025.102867>
- Liu, Y., Wang, K., Xing, X., Guo, H., Zhang, W., Luo, Q., Gao, S., Huang, Z., Li, H., Li, X., Wang, J., Wang, J., & Zhu, D. (2023). On spatial effects in geographical analysis. *Dili Xuebao/Acta Geographica Sinica*, 78(3), 517–531. <https://doi.org/10.11821/dlxb202303001>
- Mahara, D. O., & Fauzan, A. (2021). Impacts of Human Development Index and Percentage of Total Population on Poverty using OLS and GWR models in Central Java, Indonesia. *EKSAKTA: Journal of Sciences and Data Analysis*, 2(2), 142–154. <https://doi.org/10.20885/eksakta.vol2.iss2.art8>
- Mala, F., & Hidayat, M. F. (2023). Pemodelan Indeks Pembangunan Manusia Nusa Tenggara Barat Menggunakan Geographically Weighted Regression. *Euler: Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(2), 339–350. <https://doi.org/10.37905/euler.v11i2.23042>
- Meilinna, T. Z., Alfunnuria, V. S., Safira, Y. E., & Kholid, M. K. A. (2023). Pengaruh usia harapan hidup, rata-rata lama sekolah, dan pengeluaran per kapita terhadap IPM. *Jurnal Ekonomi, Bisnis Dan Manajemen*, 3(1), 12–29. <https://doi.org/10.58192/ebismen.v3i1.1613>
- Nasir, S., Kea, A. Z., Steege, R., Limato, R., Tumbelaka, P., Datiko, D. G., Kok, M., Ahmed, R., Taegtmeier, M., Tumbelaka, P., Datiko, D. G., Kok, M., & Ahmed, R. (2020). Cultural norms create a preference for traditional birth attendants and hinder health facility-based childbirth in Indonesia and Ethiopia : a qualitative inter-country study. *International Journal of Health Promotion and Education*, 00(00), 1–15. <https://doi.org/10.1080/14635240.2020.1719862>
- Nugroho, F. D. (2024). Analisis Disparitas Indeks Pembangunan Manusia Terhadap Kemiskinan Di Provinsi Daerah Istimewa Yogyakarta. 4(02), 7823–7830. <https://dspace.uui.ac.id/handle/123456789/52263>

- Pagliarella, M. C. (2021). Small Area Estimation Diagnostics: The Case of the Fay– Herriot Model. *Studies in Classification, Data Analysis, and Knowledge Organization*, 149–162. https://doi.org/10.1007/978-3-030-69944-4_16
- Paramita, B., Matzarakis, A., & Barua, P. (2023). *Increasing Temperature Risk and Community Resilience : Urban Aspects*. https://doi.org/10.1007/978-3-031-22112-5_13
- Priliyan, A. M., & Mahdy, I. F. (2022). Pemodelan Multiscale Geographically Weighted Regression (MGWR) pada Tingkat Pengangguran Terbuka di Provinsi Jawa Barat Tahun 2022. *Bandung Conference Series: Statistics*, 330–336. <https://doi.org/https://doi.org/10.29313/bcss.v4i2.12708>
- Purwaningsih, T., Inderanata, R. N., & Fauziah, M. R. (2023). Spatial Analysis of Human Development Index by Province in Indonesia 2018-2020. *AIP Conference Proceedings*, 020027(May), 1–7. <https://doi.org/10.1063/5.0136938>
- Rodiyah, A., Kusuma, D. P., Ramadani, N. B., Ibrahim, R. M., Huda, R. A., & Rahajeng, A. (2025). Pengaruh Rata Rata Lama Sekolah , Garis Kemiskinan , dan Usia Harapan Hidup terhadap IPM di Provinsi Jawa Tengah. *Jurnal Ilmiah Ekonomi Dan Manajemen*, 3(5), 345–357. <https://doi.org/10.61722/jiem.v3i5.4759>
- Satyahadewi, N., Sinaga, S. J., & Perdana, H. (2023). Hierarchical Cluster Analysis of Districts/Cities in North Sumatra Province Based on Human Development Index Indicators Using Pseudo-F. *Barekeng*, 17(3), 1429–1438. <https://doi.org/10.30598/barekengvol17iss3pp1429-1438>
- Shabrina, Z., Buyuklieva, B., & Ng, M. K. M. (2021). Short-Term Rental Platform in the Urban Tourism Context: A Geographically Weighted Regression (GWR) and a Multiscale GWR (MGWR) Approaches. *Geographical Analysis*, 53(4), 686–707. <https://doi.org/10.1111/gean.12259>
- Yulianti, S., Widyaningsih, Y., & Nurrohmah, S. (2021). Spatial panel data model on human development index at Central Java. *Journal of Physics: Conference Series*, 1722, 1–8. <https://doi.org/10.1088/1742-6596/1722/1/012090>