



Analisis Spasial dan Variasi Lokal Merchant QRIS Menggunakan Adaptive Geographically Weighted Regression

Muhammad Rafli Werizky*, Moh Ferdinand Ramdhani, Muh Taqiyudin Ibadurrahman, Mutiara Hasanah, Ilham Wira Kurniawan, Bryant Cianata, Shaifudin Zuhdi

Fakultas Teknologi Informasi dan Sains Data, Program Studi Informatika, Universitas Sebelas Maret, Surakarta, Indonesia

Email: ^{1,*}mraflwrzky@student.uns.ac.id, ²mohferdinandramdhani@student.uns.ac.id, ³muhtaqiy28@student.uns.ac.id, ⁴mutiarahasanah@student.uns.ac.id, ⁵ilhamwira28@student.uns.ac.id, ⁶bryantcianata446@student.uns.ac.id, ⁷zuhdi@staff.uns.ac.id
Email Penulis Korespondensi: mraflwrzky@student.uns.ac.id

Abstrak—Sistem pembayaran digital Indonesia bergantung pada *Quick Response Code Indonesian Standard* (QRIS). Namun, distribusinya di Indonesia masih menunjukkan ketimpangan spasial antara wilayah barat dan timur. Penelitian ini bertujuan untuk menganalisis variasi lokal serta faktor-faktor yang memengaruhi jumlah merchant QRIS di provinsi-provinsi di Indonesia pada tahun 2024. Penelitian ini menggunakan metode *Adaptive Geographically Weighted Regression* (AGWR) dengan fungsi kernel adaptive bisquare untuk menangani perbedaan spasial yang tidak dapat dijelaskan oleh regresi global. PDRB per kapita, lama sekolah rata-rata, infrastruktur digital, tingkat urbanisasi, kepadatan penduduk, jumlah Usaha Mikro, Kecil, dan Menengah dan akses internet adalah variabel independen. Hasil analisis menunjukkan bahwa AGWR memiliki performa lebih baik dibandingkan *Ordinary Least Square* (OLS) dengan *Coefficient of Determination* (R^2) meningkat dari 0,806 menjadi 0,976 dan *Adjusted R²* dari 0,751 menjadi 0,905. Selain itu, nilai *Akaike Information Criterion* (AIC) menurun dari 1003,417 menjadi 967,981 dan *Sum of Squared Errors* (SSE) turun signifikan dari $1,91 \times 10^{13}$ menjadi $2,32 \times 10^{12}$. Temuan empiris menunjukkan bahwa variabel jumlah UMKM adalah faktor paling konsisten yang memengaruhi adopsi QRIS di sebagian besar wilayah. Secara spesifik, faktor-faktor sosial-ekonomi berpengaruh signifikan di Pulau Jawa, tetapi tidak berpengaruh di wilayah Indonesia Timur (Papua dan Maluku). Ini menunjukkan adanya kendala struktural lain di kawasan tersebut. Penelitian ini merekomendasikan kebijakan inklusi keuangan yang bersifat spesifik lokasi daripada pendekatan umum nasional.

Kata Kunci: QRIS; Ekonomi Digital; *Adaptive Geographically Weighted Regression* (AGWR); Heterogenitas Spasial; UMKM

Abstract—Indonesia's digital payment ecosystem increasingly relies on the Quick Response Code Indonesian Standard (QRIS). However, its distribution still exhibits clear spatial disparities between western and eastern regions. This study aims to analyze local variations and the determinants influencing the number of QRIS merchants across Indonesian provinces in 2024. The analysis employs Adaptive Geographically Weighted Regression (AGWR) with an adaptive bisquare kernel to capture spatial heterogeneity that cannot be explained by global models such as Ordinary Least Squares (OLS). The independent variables used include Gross Regional Domestic Product per capita, average years of schooling, digital infrastructure, urbanization rate, population density, number of Micro, Small, and Medium Enterprises (MSMEs), and internet access. The results indicate that AGWR outperforms OLS, with the Coefficient of Determination (R^2) increasing from 0,806 to 0,976 and the Adjusted R^2 from 0,751 to 0,905. Additionally, the Akaike Information Criterion (AIC) decreases from 1003,417 to 967,981, while the Sum of Squared Errors (SSE) drops significantly from $1,91 \times 10^{13}$ to $2,32 \times 10^{12}$. The empirical findings reveal that the number of MSMEs is the most consistent determinant of QRIS adoption across regions. Socioeconomic factors exhibit strong influence in Java but show limited relevance in eastern provinces such as Papua and Maluku, suggesting the presence of structural constraints in these areas. This study recommends implementing location-specific financial inclusion strategies rather than uniform national policies.

Keywords: QRIS; Digital Economy; Adaptive Geographically Weighted Regression (AGWR); Spatial Heterogeneity; MSMEs

1. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi dalam satu dekade terakhir telah mempercepat transformasi ekonomi global, termasuk di Indonesia. Salah satu wujud transformasi tersebut adalah meningkatnya pemanfaatan sistem pembayaran digital yang menawarkan efisiensi, keamanan, dan kemudahan akses bagi masyarakat. *Quick Response Code Indonesian Standard* (QRIS) merupakan bentuk inovasi pembayaran non-tunai yang saat ini menjadi pilar penting dalam digitalisasi sistem keuangan nasional. Implementasi QRIS telah membuka peluang bagi percepatan inklusi ekonomi, khususnya bagi pelaku usaha mikro, kecil, dan menengah (UMKM) karena memberikan akses transaksi yang lebih cepat, murah, dan kompatibel lintas penyelenggara (Ardasanti et al., 2025).

Pertumbuhan penggunaan QRIS mengalami lonjakan yang sangat signifikan. Data dari Asosiasi Sistem Pembayaran Indonesia (ASPI) menunjukkan bahwa jumlah transaksi QRIS sepanjang tahun 2024 mencapai 6,24 miliar transaksi, meningkat sebesar 192% dari tahun 2023. Distribusi transaksi *off-us* menunjukkan kontribusi sebesar 33,97% dari usaha kecil, 31,24% dari usaha menengah, 17,93% dari usaha mikro, dan 16,05% dari usaha besar. Dari sisi nilai transaksi, usaha menengah berkontribusi sebesar 33,84%, diikuti usaha kecil 32,56%, usaha besar 18,98%, dan usaha mikro 13,49%. Angka-angka tersebut menggambarkan bahwa QRIS tidak hanya diterima secara luas oleh masyarakat, tetapi juga semakin berperan sebagai instrumen penting dalam arus ekonomi digital nasional.

Meskipun pertumbuhannya pesat, perkembangan QRIS menunjukkan ketimpangan spasial yang cukup jelas. Indonesia memiliki karakteristik geografis dan demografis yang sangat beragam, sehingga adopsi teknologi digital tidak terjadi secara merata. Infrastruktur telekomunikasi yang belum optimal di beberapa wilayah, tingkat literasi digital yang berbeda-beda, serta variasi kapasitas ekonomi lokal menyebabkan pemanfaatan QRIS lebih terpusat di kawasan perkotaan dan provinsi dengan aktivitas ekonomi tinggi (Bani Rachmad & Raharjo, 2023). Pada penelitian sebelumnya terkait pemanfaatan QRIS masih terdapat kendala seperti keterbatasan literasi digital, infrastruktur yang belum merata,



serta kekhawatiran terkait keamanan siber, khususnya di daerah terpencil (Nabila Zalzabila, 2025). Kondisi ini mengindikasikan bahwa manfaat ekonomi dari digitalisasi belum dinikmati dan dirasakan secara merata dan berpotensi memperlebar kesenjangan wilayah. Ketimpangan ini menjadi isu strategis karena distribusi *merchant* QRIS turut menentukan akses masyarakat terhadap layanan keuangan digital yang secara langsung berpengaruh pada tingkat partisipasi ekonomi daerah dan kemampuan wilayah dalam memanfaatkan peluang ekonomi digital secara optimal.

Berbagai sumber literatur menjelaskan faktor-faktor yang berhubungan dengan adopsi pembayaran digital. QRIS terbukti dapat meningkatkan kondisi keuangan UMKM melalui perluasan akses transaksi dan efisiensi pembayaran (Ardasanti et al., 2025). Faktor demografi seperti pendidikan dan akses teknologi juga berpengaruh terhadap penggunaan layanan keuangan digital di Indonesia (Swastika et al., 2024). Di tingkat makro, perkembangan pembayaran digital berkontribusi positif terhadap pertumbuhan PDB dengan cara menurunkan biaya transaksi, meningkatkan efisiensi pasar, dan mempercepat perputaran uang di sistem ekonomi (Birigozzi et al., 2025). Variabel-variabel yang banyak digunakan dalam kajian digitalisasi ekonomi tersebut memiliki dasar teoretis yang kuat. PDRB per kapita mencerminkan kapasitas ekonomi suatu wilayah, rata-rata lama sekolah berkaitan dengan literasi dan kemampuan adaptasi teknologi, jumlah UMKM menggambarkan potensi permintaan *merchant*, sedangkan akses internet menjadi prasyarat fundamental bagi penggunaan layanan digital seperti QRIS. Selain itu, akses dan infrastruktur TIK berperan penting karena kualitas jaringan dan ketersediaan infrastruktur digital menentukan kemampuan masyarakat dan pelaku usaha dalam memanfaatkan layanan keuangan elektronik, wilayah dengan indeks TIK tinggi cenderung menunjukkan adopsi QRIS yang lebih besar (Fakriah et al., 2025). Urban rate juga berkaitan erat dengan tingkat modernisasi suatu daerah; wilayah urban biasanya memiliki fasilitas teknologi lebih baik dan akses layanan digital yang lebih luas, sehingga mendorong penggunaan QRIS (Priya, G. M. & Shalini, P., 2025). Kepadatan penduduk menggambarkan konsentrasi aktivitas ekonomi dan potensi pasar, daerah dengan jumlah penduduk padat cenderung memiliki intensitas transaksi yang lebih tinggi sehingga meningkatkan relevansi pemanfaatan pembayaran digital (Mindawati & Nugroho, 2025).

Selain aspek digitalisasi, pendekatan spasial berperan penting dalam memahami variasi geografis suatu fenomena. Teknik pemodelan berbasis spasial seperti *Geographically Weighted Regression* (GWR) mampu menangkap heterogenitas antarwilayah dan menghasilkan estimasi yang lebih akurat dibandingkan model global yang mengasumsikan keseragaman hubungan antarvariabel (Miranti et al., 2024). Dalam konteks Indonesia yang memiliki keragaman wilayah yang tinggi, kemampuan model untuk menangkap dinamika lokal menjadi sangat relevan. Namun, pendekatan spasial belum banyak diterapkan dalam kajian terkait infrastruktur pembayaran digital, khususnya pada sisi penawaran berupa jumlah *merchant* QRIS. Sebagian besar analisis masih mengasumsikan bahwa hubungan antara faktor ekonomi, sosial, dan digitalisasi bersifat homogen di semua provinsi.

Penggunaan model regresi global seperti *Ordinary Least Squares* (OLS) memiliki keterbatasan dalam menjelaskan ketidakseragaman tersebut karena setiap koefisien dianggap berlaku sama di seluruh wilayah (Huang et al., 2023). Padahal, pengaruh variabel seperti PDRB per kapita, pendidikan, jumlah UMKM, dan akses internet sangat mungkin beragam antara provinsi dengan struktur ekonomi maju dan provinsi yang masih memiliki keterbatasan infrastruktur digital. Oleh karena itu, pendekatan *Adaptive Geographically Weighted Regression* (AGWR) diperlukan untuk menangani heterogenitas spasial tersebut, mengingat metode global biasa tidak mampu untuk menangkap parameter regresi yang berubah di setiap lokasi sesuai karakteristik wilayah masing-masing. Dengan memanfaatkan *Adaptive* kernel, AGWR dapat menggunakan bandwidth yang berbeda-beda untuk setiap titik pengamatan, serta memiliki kemampuan untuk menyesuaikan dengan variabilitas kondisi di lokasi pengamatan tersebut (Tangka et al., 2024). Dengan demikian, model dapat mengungkap pola pengaruh yang lebih realistis dan membantu memahami bagaimana faktor-faktor ekonomi dan digital bekerja secara berbeda di berbagai provinsi. Pendekatan ini juga memberikan kontribusi analitis yang penting karena mampu menunjukkan sensitivitas setiap variabel secara spasial, sehingga hasil yang diperoleh dapat dijadikan landasan kebijakan yang lebih tepat sasaran dan kontekstual sesuai kondisi tiap provinsi.

Berdasarkan kondisi tersebut, diperlukan analisis yang mampu menjelaskan ketimpangan spasial dalam distribusi *merchant* QRIS secara lebih komprehensif. Penelitian ini bertujuan untuk menganalisis pengaruh faktor ekonomiyang mencakup PDRB per kapita, rata-rata lama sekolah, dan jumlah UMKM serta faktor infrastruktur digital berupa akses internet dan lainnya terhadap jumlah *merchant* QRIS di 33 provinsi di Indonesia. Selain itu, penelitian ini bertujuan mengidentifikasi variasi lokal dari pengaruh tiap variabel sehingga dapat memberikan gambaran yang lebih akurat mengenai dinamika spasial perkembangan ekonomi digital di Indonesia. Hasil analisis diharapkan memberikan dasar empiris yang kuat untuk perumusan kebijakan berbasis wilayah dalam rangka mendorong pemerataan inklusi ekonomi digital nasional.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan analisis spasial yang bertujuan untuk menganalisis distribusi dan variasi lokal *merchant* QRIS di Indonesia pada tahun 2024 serta keterkaitannya dengan faktor-faktor sosial ekonomi dan infrastruktur digital. Lokasi penelitian mencakup seluruh wilayah Indonesia dengan unit analisis 33 provinsi sebagai basis observasi spasial.

Variabel dependen (Y) dalam penelitian ini adalah jumlah *merchant* QRIS yang diperoleh dari Buletin Statistik ASPI Sistem Pembayaran QRIS Quarter IV Tahun 2024. Variabel ini merepresentasikan tingkat adopsi sistem pembayaran digital QRIS di setiap provinsi. QRIS dipandang sebagai instrumen penting dalam mendorong inklusi keuangan UMKM serta mendukung pertumbuhan ekonomi digital nasional (Haryanti, 2024) .

Variabel independen yang digunakan dalam penelitian ini terdiri dari tujuh variabel. Dimulai dari Produk Domestik Regional Bruto (PDRB) per kapita yang merepresentasikan tingkat kesejahteraan ekonomi daerah, rata-rata lama sekolah sebagai indikator tingkat pendidikan masyarakat, akses dan infrastruktur Teknologi Informasi dan Komunikasi (TIK) yang mencerminkan kesiapan infrastruktur digital suatu wilayah, *urban rate* yang menggambarkan tingkat urbanisasi di setiap provinsi, kepadatan penduduk sebagai indikator intensitas aktivitas sosial ekonomi, jumlah UMKM yang mencerminkan potensi pelaku ekonomi skala mikro dan kecil, dan persentase penduduk yang mengakses internet sebagai indikator adopsi teknologi digital masyarakat. Seluruh data independen diperoleh dari Badan Pusat Statistik (BPS) dan publikasi nasional lainnya yang bersifat resmi, terverifikasi, dan terbaru, sehingga menjamin validitas data dalam proses analisis.


Hipotesis dalam penelitian ini menyatakan bahwa ketujuh variabel independen memiliki pengaruh signifikan terhadap distribusi dan variasi jumlah *merchant* QRIS di Indonesia. Asumsi tersebut didasarkan pada anggapan bahwa ketujuh variabel independen tersebut merupakan determinan utama dalam mendorong adopsi sistem pembayaran digital dan penguatan inklusi keuangan berbasis teknologi.

Metode analisis yang digunakan dalam penelitian ini meliputi *Ordinary Least Squares* (OLS) sebagai model global untuk mengidentifikasi pengaruh variabel secara umum, serta *Adaptive Geographically Weighted Regression* (AGWR) dengan *adaptive* kernel untuk menangkap variasi pengaruh variabel secara lokal di setiap provinsi. Pendekatan AGWR dipilih karena mampu mengakomodasi heterogenitas spasial yang tidak dapat dijelaskan secara optimal oleh model regresi global.

Kerangka pemikiran penelitian diawali dari identifikasi permasalahan ketimpangan distribusi *merchant* QRIS antar provinsi, dilanjutkan dengan pengumpulan data sekunder dari berbagai sumber resmi, analisis statistik deskriptif, pemodelan regresi global menggunakan OLS, pengujian asumsi klasik dan asumsi spasial, serta pemodelan AGWR untuk mengidentifikasi pola variasi lokal. Seluruh tahapan tersebut menjadi dasar dalam perumusan strategi penguatan inklusi ekonomi digital di Indonesia.

2.2 Tahapan Penelitian

Tahapan penelitian ini disusun secara sistematis dimulai dari pengumpulan data hingga diperolehnya hasil analisis spasial yang optimal. Tahapan penelitian bertujuan untuk memastikan bahwa penerapan metode, proses pengujian, serta interpretasi hasil dilakukan secara terstruktur dan sesuai dengan tujuan penelitian. Adapun tahapan penelitian yang dilakukan dalam penelitian ini terdiri atas beberapa tahap seperti pada Gambar 1 berikut.



Gambar 1. Alur Tahapan Penelitian

Berdasarkan Gambar 1, kerangka kerja penelitian dirancang dengan pendekatan sekuensial yang bergerak dari analisis global menuju analisis lokal. Fase awal berfokus pada validasi input melalui pengumpulan dan pra-pemrosesan data untuk menjamin integritas dataset. Tahap inti dimulai dengan pembangunan model global (OLS) sebagai baseline untuk mengidentifikasi hubungan variabel secara umum.

2.2.1 Pra-Pemrosesan Data

Tahap pra-pemrosesan data merupakan tahapan yang sangat penting untuk memastikan dan mendapatkan hasil dengan kualitas yang terbaik. Pada tahap ini memiliki beberapa tahapan sebagai berikut :

- Seleksi Variabel (*Feature Selection*):** Seleksi variabel dilakukan untuk memastikan bahwa hanya variabel yang relevan dengan tujuan penelitian. Berdasarkan kerangka konsep penelitian, variabel yang digunakan terdiri atas satu variabel dependen (Y) dan tujuh variabel independen (x), serta data koordinat (*longitude* dan *latitude*) yang diambil dari titik tengah setiap provinsi. Seluruh variabel independen dipertahankan karena memiliki keterkaitan teoritis dan empiris terhadap adopsi sistem pembayaran digital dan inklusi ekonomi berbasis teknologi. Rincian mengenai notasi, definisi operasional, satuan, serta sumber data untuk masing-masing variabel disajikan secara lengkap pada Tabel 1.

Tabel 1. Definisi Operasional Variabel

Variabel	Notasi	Definisi/Satuan	Sumber Data
Jumlah Merchant QRIS	Y	Total merchant terdaftar QRIS (Unit)	Buletin Statistik ASPI Q4 2024



Variabel	Notasi	Definisi/Satuan	Sumber Data
PDRB per Kapita	x_1	Pendapatan regional rata-rata (Ribu Rp)	BPS
Rata-rata Lama Sekolah	x_2	Rata-rata lama sekolah penduduk (Tahun)	BPS
Akses dan Infrastruktur TIK	x_3	Indeks Pembangunan TIK (Skala 0–10)	BPS
Urban Rate	x_4	Persentase penduduk perkotaan (%)	BPS
Kepadatan Penduduk	x_5	Jumlah penduduk per luas wilayah (Jiwa/km ²)	BPS
Jumlah UMKM	x_6	Jumlah industri mikro dan kecil (Unit Usaha)	BPS
Akses Internet	x_7	Penduduk yang mengakses internet (%)	BPS

Sebagaimana rincian pada Tabel 1, data yang digunakan bersumber dari publikasi resmi yang terverifikasi guna menjamin validitas penelitian. Setelah variabel ditentukan dan data dikumpulkan, langkah selanjutnya adalah memastikan integritas dataset melalui proses pembersihan data.

- Pembersihan Data (*Data Cleaning*): Proses pembersihan data dilakukan untuk meningkatkan konsistensi dan akurasi data sebelum dilakukan analisis lebih lanjut dengan pemeriksaan *Missing Values* dan pemeriksaan data duplikat.
- Penyelarasan Tahun Data: Seluruh data yang digunakan dalam penelitian ini diselaraskan pada periode tahun 2024, baik untuk data jumlah *merchant* QRIS maupun seluruh variabel independen. Penyelarasan ini bertujuan untuk memastikan bahwa hubungan antar variabel dianalisis pada kerangka waktu yang sama sehingga hasil estimasi model bersifat valid dan representatif. Terkecuali untuk data *urban rate* yang menggunakan data proyeksi tahun 2025, hal ini dilakukan karena *urban rate* merupakan variabel demografis yang berubah secara gradual dan bersifat jangka panjang, penggunaan proyeksi pada satu tahun berikutnya tidak menimbulkan perubahan yang signifikan dapat dibuktikan pada (Shinta, 2024) dengan hanya menunjukkan pertumbuhan pertahun sangat kecil, yaitu hanya 1.2%.
- Standarisasi Data (*Standardization*): seluruh variabel independen distandarisasi menggunakan metode *Z-Score Standardization* sebelum pemodelan OLS dan AGWR. Standarisasi pada OLS dilakukan untuk memudahkan perbandingan besaran pengaruh antar variabel. Sedangkan pada AGWR standarisasi diperlukan untuk menjaga kestabilan estimasi parameter lokal yang dipengaruhi oleh pembobotan spasial. Proses standarisasi dilakukan seperti pada (1).

$$Z = \frac{X - \mu}{\sigma} \quad (1)$$

dengan X merupakan nilai asli variabel, μ merupakan nilai rata-rata variabel, dan σ merupakan simpangan baku variabel.

2.2.2 Pemodelan Regresi Global dengan OLS

Tahap awal analisis dilakukan dengan membangun model regresi linear. Regresi linear merupakan teknik statistik yang digunakan untuk menggambarkan serta memodelkan hubungan antara variabel dependen (Y) dan variabel independen (X) (Montgomery et al., 2021). Model ini sering disebut sebagai regresi global karena pengaruh variabel independen terhadap variabel dependen diasumsikan konstan pada setiap titik observasi, sehingga parameter yang dihasilkan bersifat sama untuk seluruh lokasi (Montgomery et al., 2021). Dalam konteks penelitian ini, asumsi tersebut berarti bahwa hubungan antara jumlah *merchant* QRIS dan variabel-variabel penjelasnya dianggap homogen di seluruh provinsi di Indonesia. Proses penaksiran parameter dalam regresi linear menggunakan pendekatan *Ordinary Least Square* (OLS). Pada metode OLS, parameter diperoleh dengan meminimalkan jumlah kuadrat selisih antara nilai observasi dan nilai prediksi. Selisih ini disebut *error*, yaitu perbedaan antara data aktual dengan nilai yang diestimasi. Dengan diperolehnya parameter yang optimal, nilai *error* dapat ditekan sekecil mungkin sehingga hasil estimasi menjadi lebih mendekati kondisi sebenarnya (Mahara & Fauzan, 2021). Secara umum, bentuk model regresi dengan pendekatan OLS ditunjukkan pada persamaan (2).

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad (2)$$

Dengan Y_i sebagai jumlah *merchant* QRIS pada provinsi ke- i , X_{ki} sebagai nilai variabel independen ke- k dan provinsi ke- i , β_0 sebagai variabel intercept, β_k sebagai koefisien regresi yang menggambarkan besar dan arah pengaruh variabel independen dan ε_i sebagai *error* yang diasumsikan berdistribusi normal dengan rata-rata nol dan varians konstan.

Evaluasi terhadap model dilakukan melalui uji signifikansi statistik. Dalam penelitian ini, tingkat signifikansi (α) ditetapkan sebesar 0,10. Penentuan nilai ambang batas ini didasarkan pada pertimbangan ukuran sampel penelitian yang terbatas, yaitu hanya 33 unit observasi (provinsi). Studi literatur terbaru menyoroti bahwa penggunaan tingkat signifikansi konvensional yang ketat (0,05) pada sampel kecil dapat menurunkan kekuatan uji statistik, yang berisiko meningkatkan *Type II Error* atau kegagalan mendeteksi pengaruh yang sebenarnya ada (Kim & Choi, 2021). Dalam konteks analisis spasial data ekonomi regional, fleksibilitas nilai α hingga 0,10 dapat diterima untuk menyeimbangkan risiko inferensi pada dataset dengan variabilitas tinggi (Mbeta et al., 2025).

Uji signifikansi dilakukan untuk mengetahui apakah variabel-variabel independen yang digunakan dalam model memiliki pengaruh yang signifikan secara statistik terhadap jumlah *merchant* QRIS. Uji signifikansi dalam regresi OLS terdiri atas dua jenis pengujian, yaitu:



- a. Uji F atau uji simultan: Uji ini digunakan untuk menguji pengaruh seluruh variabel independen secara bersama-sama terhadap variabel dependen. Hipotesis yang digunakan $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$ dan H_1 : setidaknya terdapat satu $\beta_k \neq 0$. Model dinyatakan signifikan secara simultan apabila nilai $Prob(F - statistic) < \alpha = 0.10$.
- b. Uji t atau uji parsial: Uji ini digunakan untuk menguji pengaruh masing-masing variabel independen secara individual terhadap variabel dependen. Hipotesis yang digunakan adalah $H_0: \beta_k = 0$ atau variabel ke- k tidak berpengaruh signifikan dan $H_1: \beta_k \neq 0$ atau variabel ke- k berpengaruh signifikan. Keputusan dilakukan dengan membandingkan nilai p -value dengan tingkat signifikansi $\alpha = 0.10$. Variabel dinyatakan signifikan apabila p -value $< \alpha$.

2.2.3 Pengujian Asumsi Klasik dan Asumsi Spasial

Kedua pengujian ini digunakan untuk memastikan bahwa model tersebut memenuhi asumsi-asumsi statistik oleh pendekatan *Ordinary Least Squares*. Pengujian ini terdiri atas asumsi klasik, meliputi normalitas residual, multikolinearitas, heteroskedastisitas, dan independensi, serta asumsi spasial yang menguji keberadaan pola keterkaitan spasial pada residual model.

a. Uji Asumsi Klasik: Uji asumsi klasik dilakukan untuk memastikan bahwa model regresi yang dibentuk dengan metode OLS memenuhi sifat *Best Linear Unbiased Estimator* (BLUE) dengan tujuan agar bersifat tidak bias, efisien, dan konsisten. Uji Asumsi Klasik pada kasus ini terdiri dari empat jenis pengujian, yaitu:

1. Uji Normalitas: Uji normalitas dilakukan untuk mengetahui apakah residual dalam model regresi berdistribusi normal. Pada penelitian ini digunakan uji Shapiro–Wilk, yaitu salah satu uji normalitas yang paling umum digunakan untuk sampel kecil hingga menengah dan memiliki kekuatan yang tinggi dalam mendeteksi penyimpangan dari distribusi normal (Shapiro & Wilk, 1965). Uji ini memeriksa kesesuaian antara urutan residual yang diamati dan urutan nilai residual yang diharapkan jika data mengikuti distribusi normal. Statistik uji Shapiro–Wilk dirumuskan seperti pada (3)

$$W = \frac{\left(\sum_{i=1}^n a_i x_{(i)}\right)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

dengan n menyatakan jumlah pengamatan, $x_{(i)}$ merupakan nilai residual yang telah diurutkan dari yang terkecil hingga terbesar, dan \bar{x} adalah nilai rata-rata residual. Konstanta a_i adalah koefisien yang dihitung berdasarkan varians dan kovarians dari nilai-nilai yang diharapkan dari order statistic distribusi normal. Nilai statistik W dibandingkan dengan nilai kritis atau p -value dari distribusi Shapiro–Wilk. Kriteria pengambilan keputusan dilakukan dengan membandingkan nilai p -value dengan tingkat signifikansi α . Jika p -value lebih besar dari α , maka hipotesis nol diterima dan residual dinyatakan berdistribusi normal. Sebaliknya, jika p -value lebih kecil dari α , maka residual tidak berdistribusi normal.

2. Uji Multikolinearitas: Uji ini dilakukan untuk mengetahui ada tidaknya hubungan linear yang kuat antar variabel independen dalam model regresi. Hubungan linear yang tinggi antar variabel independen dapat menyebabkan ketidakstabilan estimasi koefisien regresi. Pendeteksian multikolinearitas dilakukan menggunakan *Variance Inflation Factor* (VIF) (Hocking, 2003). Nilai VIF dirumuskan seperti pada (4).

$$VIF_j = \frac{1}{1 - R_j^2} \quad (4)$$

di mana R_j^2 merupakan koefisien determinasi hasil regresi antara satu variabel independen X_j dengan seluruh variabel independen lainnya. Kriteria pengambilan keputusan dilakukan dengan melihat nilai VIF. Jika nilai VIF lebih besar dari 10, maka terjadi multikolinearitas antar variabel independen, sedangkan jika nilai VIF kurang dari 10, maka model dianggap bebas dari multikolinearitas.

3. Uji Heteroskedastisitas: Uji heteroskedastisitas digunakan untuk melihat model regresi linear terjadi ketidaksamaan variansi residual antar pengamatan. Model regresi yang baik memiliki variansi residual yang konstan (homoskedastis) sehingga pendugaan parameter menjadi efisien. Pada penelitian ini digunakan uji Breusch–Pagan–Godfrey (*LM Test*) untuk mendeteksi ada tidaknya heteroskedastisitas. Statistik uji *Lagrange Multiplier* (LM) dihitung menggunakan rumus:

$$LM = nR^2 \quad (5)$$

dengan n menyatakan jumlah pengamatan dan R^2 merupakan koefisien determinasi hasil regresi antara residual kuadrat dengan variabel independen. Nilai statistik BP mengikuti distribusi *Ci-Square*. Hipotesis yang digunakan adalah dengan tidak terjadi heteroskedastisitas dan terjadi heteroskedastisitas. Kriteria keputusan dalam uji Breusch–Pagan–Godfrey ditetapkan dengan membandingkan nilai statistik LM dan p -value dengan batas signifikansi α . Hipotesis nol ditolak apabila nilai LM lebih besar dari nilai kritis $\chi_{\alpha,k}^2$ atau p -value $< \alpha$, yang menunjukkan bahwa terjadi heteroskedastisitas pada model. Sebaliknya, apabila nilai LM lebih kecil dari $\chi_{\alpha,k}^2$ atau p -value $> \alpha$, maka hipotesis nol diterima sehingga model dinyatakan bebas dari heteroskedastisitas dan residual memiliki variansi yang konstan.



4. Uji Independensi: Uji ini dilakukan untuk mengetahui apakah residual pada suatu lokasi bersifat bebas dari residual pada lokasi lainnya. Independensi residual akan diuji menggunakan statistik Moran's I yang digunakan untuk mengukur tingkat ketergantungan spasial antar residual (Moran, 1950). Uji ini memeriksa apakah residual yang berdekatan secara geografis cenderung memiliki pola yang saling berkaitan atau tidak. Statistik Moran's I dilihat pada (6).

$$I = \frac{n}{W} \cdot \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij}(e_i - \bar{e})(e_j - \bar{e})}{\sum_{i=1}^n (e_i - \bar{e})^2} \quad (6)$$

dengan n menyatakan jumlah pengamatan, e_i merupakan residual pada lokasi ke- i , dan \bar{e} adalah rata-rata residual. Nilai w_{ij} merupakan elemen matriks bobot spasial yang menggambarkan hubungan kedekatan antara lokasi i dan lokasi j , sedangkan W adalah jumlah keseluruhan bobot spasial. Matriks bobot spasial dibangun menggunakan pendekatan berbasis jarak, di mana jarak antar wilayah dihitung menggunakan jarak Haversine berdasarkan koordinat lintang dan bujur pusat provinsi dengan alasan pengambilan karena wilayah tidak selalu berbatasan langsung. Pengambilan keputusan dilakukan dengan membandingkan nilai p -value hasil pengujian dengan tingkat signifikansi α . Jika p -value lebih kecil dari α , maka terdapat autokorelasi spasial pada residual. Sebaliknya, jika p -value lebih besar dari α , maka residual dinyatakan independen secara spasial dan model OLS memenuhi asumsi independensi residual.

- b. Uji Asumsi Spasial: Pengujian ini dilakukan untuk menilai apakah model regresi global OLS telah mampu menggambarkan variasi yang terjadi pada data spasial atau apakah terdapat indikasi bahwa hubungan antara variabel-variabel penelitian bersifat unik dan tidak homogen dalam setiap lokasi pengamatan. Dua aspek utama yang diuji dari pengujian ini, yaitu:

1. Uji Heterogenitas Spasial: Uji heterogenitas spasial digunakan untuk mengetahui apakah terdapat perbedaan pengaruh variabel independen terhadap variabel dependen antar lokasi. Salah satu metode yang digunakan untuk mendeteksi heterogenitas spasial adalah uji Breusch-Pagan (BP) dalam konteks spasial, yaitu pengembangan dari uji heteroskedastisitas yang diarahkan untuk memeriksa ada tidaknya variasi struktural pada parameter regresi di ruang (Anselin, 1988). BP yang akan digunakan dapat dilihat pada (7).

$$BP = \frac{1}{2} f^T Z (Z^T Z)^{-1} Z^T f \quad (7)$$

vektor f dihitung untuk setiap pengamatan ke- t sebagai $f_t = \left(\frac{e_t^2}{\sigma^2} - 1 \right)$, di mana e_t merupakan residual untuk pengamatan ke- i dengan asumsi $e \sim IID N(0, \sigma^2)$, dan σ^2 merupakan ragam residual. Matriks Z merepresentasikan variabel-variabel yang telah distandarisisasi dengan ukuran $n \times (p + 1)$, sedangkan nilai BP mengukur seberapa besar variasi spasial yang terjadi dalam struktur kesalahan model. Apabila nilai p -value lebih kecil dari tingkat signifikansi α , maka hipotesis nol yang menyatakan tidak adanya variabilitas spasial ditolak, sehingga dapat disimpulkan bahwa terdapat heterogenitas spasial dan model OLS tidak lagi dapat dianggap homogen antar wilayah.

2. Uji Autokorelasi Spasial: Uji autokorelasi spasial dilakukan untuk menilai apakah residual menunjukkan pola pengelompokan, penyebaran, atau distribusi acak secara geografis. Statistik Moran's I dapat dilihat pada (6) dengan matriks bobot spasial juga dibangun dengan pendekatan berbasis jarak menggunakan jarak Haversine. Nilai Moran's I positif menunjukkan adanya pengelompokan wilayah dengan residual yang mirip, sedangkan nilai negatif menunjukkan pola penyebaran. Nilai Moran's I mendekati nol mengindikasikan bahwa residual terdistribusi secara acak. Interpretasi autokorelasi spasial dilakukan berdasarkan nilai statistik I dan p -value yang diperoleh. Jika hasil pengujian menunjukkan nilai p -value lebih kecil dari tingkat signifikansi α , maka terdapat autokorelasi spasial yang signifikan. Sebaliknya, jika nilai p -value lebih besar dari α , maka tidak terdapat autokorelasi spasial yang berarti.

2.2.4 Pemodelan Adaptive Geographically Weighted Regression (AGWR)

Pemodelan *Adaptive Geographically Weighted Regression* (AGWR) digunakan ketika hubungan antara variabel independen dan variabel dependen diduga tidak bersifat homogen di seluruh wilayah, melainkan bervariasi secara spasial. AGWR memungkinkan setiap lokasi memiliki nilai parameter regresi yang berbeda sehingga mampu menangkap variasi lokal dan pola spasial yang tidak dapat dijelaskan oleh model global. Secara umum, model AGWR dapat dinyatakan seperti pada (8).

$$Y_i = \beta_0(u_i, v_i) + \sum_{k=1}^p \beta_k(u_i, v_i) X_{ki} + \varepsilon_i \quad (8)$$

di mana (u_i, v_i) merupakan koordinat geografis provinsi ke- i , X_{ki} adalah nilai variabel independen ke- k , dan $\beta_k(u_i, v_i)$ adalah koefisien regresi lokal yang berbeda pada setiap lokasi. Perbedaan koefisien antar wilayah mencerminkan adanya *spatial non-stationarity*, yaitu variasi hubungan antar variabel yang berubah mengikuti lokasi.

AGWR membutuhkan informasi kedekatan antar lokasi untuk menentukan bobot spasial. Bobot spasial pada AGWR dibangun menggunakan matriks bobot spasial berbasis jarak juga di mana kedekatan antar provinsi direpresentasikan oleh jarak geografis antar pusat wilayah. Jarak antar provinsi dihitung menggunakan rumus haversine, yaitu metode



perhitungan jarak geodesik yang mempertimbangkan kelengkungan bumi. Pendekatan berbasis jarak ini dipilih karena unit analisis berupa wilayah tingkat provinsi yang tidak selalu berbatasan langsung, sehingga pembobotan berbasis kontiguitas kurang representatif. Persamaan haversine dapat dilihat pada (9).

$$d_{ij} = 2R \arcsin \left[\left(\sin^2 \left(\frac{\Delta\phi}{2} \right) + \cos(\phi_i) \cos(\phi_j) \sin^2 \left(\frac{\Delta\lambda}{2} \right) \right)^{1/2} \right] \quad (9)$$

dengan R menyatakan jari-jari bumi, ϕ_i dan ϕ_j adalah lintang provinsi i dan j , sedangkan $\Delta\phi$ dan $\Delta\lambda$ masing-masing adalah selisih lintang dan bujur.

Komponen utama AGWR adalah pemilihan *bandwidth*, yaitu parameter yang menentukan seberapa luas wilayah yang diperhitungkan dalam estimasi koefisien lokal. Penelitian ini menggunakan *adaptive bandwidth*, yaitu *bandwidth* yang menyesuaikan jumlah tetangga terdekat berdasarkan kepadatan spasial. Wilayah yang saling berdekatan akan memiliki *bandwidth* yang lebih kecil, sedangkan wilayah yang jaraknya lebih tersebar akan memiliki *bandwidth* yang lebih besar. Pemilihan *bandwidth* optimal dilakukan dengan meminimalkan fungsi *Cross-Validation* (CV) seperti pada (10)

$$CV(b) = \sum_{i=1}^n (y_i - \hat{y}_{(-i)}(b))^2 \quad (10)$$

Bandwidth b yang menghasilkan nilai CV minimum dipilih sebagai *bandwidth* terbaik karena memberikan hasil prediksi lokal yang paling akurat.

Proses pembobotan dilakukan menggunakan *adaptive bisquare kernel*, yaitu fungsi pembobot yang memberikan bobot penuh pada lokasi-lokasi yang berada dalam jangkauan *bandwidth*, dan bobot nol pada lokasi yang jaraknya melampaui *bandwidth* tersebut. Fungsi pembobot dapat dilihat pada (11).

$$w_{ij} = \begin{cases} \left[1 - \left(\frac{d_{ij}}{b_i} \right)^2 \right]^2, & \text{jika } d_{ij} < b_i \\ 0, & \text{jika } d_{ij} \geq b_i \end{cases} \quad (11)$$

Pada rumus tersebut, d_{ij} merupakan jarak haversine antara provinsi i dan j , sedangkan b_i adalah *adaptive bandwidth* pada lokasi ke- i .

Pada lokasi ke- i , parameter model AGWR diestimasi menggunakan metode *Weighted Least Squares* (WLS), di mana matriks bobot lokal $W(u_i, v_i)$ dibentuk berdasarkan *adaptive kernel*. Estimator koefisien lokal diberikan oleh persamaan (12):

$$\hat{\beta}(u_i, v_i) = (X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i) Y \quad (12)$$

Dengan $W(u_i, v_i) = \text{diag}(w_1(u_i, v_i), \dots, w_n(u_i, v_i))$ yang mencerminkan kedekatan geografis antar provinsi yang akan diuji.

Pengujian *Goodness of Fit* (GOF) dilakukan untuk menilai apakah model AGWR memberikan peningkatan kecocokan yang signifikan dibandingkan model regresi global OLS. Secara formal, hipotesis yang diuji adalah $H_0: \beta_k(u_i, v_i) = \beta_k$ untuk seluruh k yang menyatakan bahwa seluruh koefisien regresi bersifat global dan $H_1: \exists \beta_k(u_i, v_i) \neq \beta_k$ yang menyatakan bahwa paling sedikit terdapat satu koefisien regresi yang berbeda antar lokasi. Statistik uji F digunakan untuk membandingkan kecocokan kedua model dan dapat dilihat pada (13).

$$F = \frac{(SSE_{OLS} - SSE_{AGWR})/df_1}{SSE_{AGWR}/df_2} \quad (13)$$

Dengan SSE_{OLS} adalah jumlah kuadrat residual model OLS, SSE_{AGWR} adalah jumlah kuadrat residual model AGWR, $df_1 = n - p$ adalah derajat bebas pembilang, dan $df_2 = n - 2 \text{tr}(S) + \text{tr}(S^T S)$ adalah derajat bebas penyebut. Matriks S merupakan matriks *hat* dari model AGWR. Keputusan pengujian diambil dengan membandingkan nilai F dengan nilai kritis F_{α, df_1, df_2} . Jika $F \geq F_{\text{tabel}}$, maka hipotesis nol ditolak, yang berarti model spasial memberikan peningkatan kecocokan yang signifikan dibandingkan OLS.

2.2.5 Evaluasi dan Perbandingan Model

a. Uji Signifikansi Parameter Lokal: Uji ini akan melihat pengaruh signifikansi parameter regresi pada setiap lokasi melalui uji t lokal. t lokal pada lokasi ke- i dirumuskan pada persamaan (14):

$$t_{ik} = \frac{\hat{\beta}_k(u_i, v_i)}{SE(\hat{\beta}_k(u_i, v_i))} \quad (14)$$

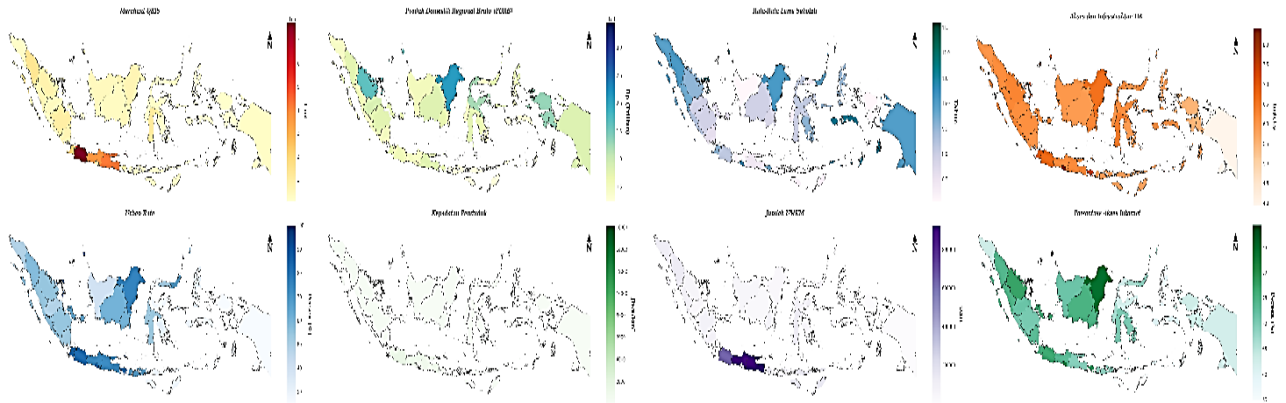
di mana $\hat{\beta}_k(u_i, v_i)$ merupakan koefisien regresi lokal untuk variabel ke- k pada lokasi ke- i , dan $SE(\hat{\beta}_k(u_i, v_i))$ adalah *standard error* dari koefisien tersebut. Nilai t_{ik} kemudian dibandingkan dengan nilai kritis distribusi t pada tingkat signifikansi tertentu. Jika $|t_{ik}| > t_{\text{tabel}}$, maka variabel ke- k dinyatakan berpengaruh signifikan pada lokasi tersebut.

b. Pemilihan Model Terbaik: Pemilihan model terbaik berdasarkan nilai AIC, SSE, R^2 dan *Adjusted R²* antara model regresi OLS dan AGWR.

3. HASIL DAN PEMBAHASAN

3.1 Statistik Deskriptif Variabel Penelitian

Data persebaran *merchant* QRIS beserta faktor-faktor yang mempengaruhi persebaran di berbagai provinsi didapatkan dari berbagai sumber seperti Badan Pusat Statistik. Data-data tersebut diolah dan disajikan pada peta persebaran data variabel di Indonesia seperti di Gambar 2.



Gambar 2. Persebaran Data Variabel di Indonesia

Dilihat dari Gambar 2, persebaran variabel dependen dan independen di Indonesia menunjukkan pola spasial yang tidak merata di antara berbagai daerah, dengan nilai yang cenderung lebih tinggi di provinsi-provinsi barat dan berkurang secara bertahap menuju area timur. Hal ini terlihat ketika dibandingkan dengan karakteristik daerah, misalnya provinsi seperti DKI Jakarta, Jawa Barat, dan Jawa Timur, yang dalam dataset secara konsisten menunjukkan nilai tertinggi pada hampir semua indikator. Sebagai contoh, Jawa Barat memiliki sejumlah *merchant* QRIS sebanyak 7,7 juta, memiliki PDRB lebih dari Rp 300 triliun, jumlah UMKM lebih dari 900.000 unit, serta akses internet untuk masyarakat yang melebihi 83%. Kondisi tersebut sejalan dengan tingkat urbanisasi tinggi yang terjadi di Jawa Barat, yang mencapai sekitar 70%, sehingga mendorong peningkatan aktivitas ekonomi dan penerapan teknologi. Pola dominasi di wilayah barat ini menunjukkan bahwa provinsi dengan populasi besar dan pusat kegiatan ekonomi memiliki nilai variabel dependen yang jauh lebih tinggi.

Di sisi lain, persebaran nilai variabel menunjukkan kecenderungan yang rendah di provinsi-provinsi di kawasan timur seperti Papua, Maluku, dan Nusa Tenggara Timur. Pada peta, daerah-daerah ini tampil dalam kategori warna paling terang, menunjukkan bahwa nilai tersebut berada di level terbawah dalam persebaran. Misalnya, akses internet di Papua dan Maluku hanya sekitar 55–60%, jumlah UMKM tidak sampai 100.000 unit, dan tingkat urbanisasi yang tidak mencapai 30%. Pada indikator pendidikan, rata-rata lama sekolah di beberapa provinsi di timur juga berada pada rentang 7–8 tahun, jauh di bawah provinsi seperti DKI Jakarta atau Jogja yang bisa mencapai 10–11 tahun. Pola ini mengindikasikan bahwa faktor geografis, tingkat keterisolasian sebuah daerah, serta kekurangan infrastruktur berpengaruh besar terhadap rendahnya nilai variabel dependen di kawasan timur.

Secara keseluruhan, kombinasi angka dan visualisasi menyoroti bahwa persebaran variabel dependen di Indonesia menggarisbawahi pola jelas dari barat ke timur: wilayah barat (Sumatra, Jawa, Bali) mendominasi nilai yang tinggi, sedangkan wilayah timur (NTT, Maluku, Papua) berada di posisi tertinggal dengan nilai yang rendah. Data persebaran variabel akan diperhitungkan nilai-nilai minimal, maksimal, rata-rata, dan simpangan baku. Setelah melakukan perhitungan, data tersebut disajikan dalam bentuk Tabel 2.

Tabel 2. Statistik Deskriptif Data

Variabel	Count	Min	Max	Mean	Std
Y	33	81000	7732000	1083545,455	1751821,768
x_1	33	24272000	344350000	83306272,727	62086863,062
x_2	33	8,070	11,590	9,270	0,862
x_3	33	3,940	8,410	6,234	0,732
x_4	33	25,200	100	56,864	19,520
x_5	33	10	16165	778,424	2791,858
x_6	33	1858	925985	133190,455	227105,173
x_7	33	54,840	89,260	71,469	7,839

Statistik deskriptif dalam Tabel 2 menunjukkan bahwa variabel dependen Y (*Merchant* QRIS) menunjukkan variasi yang sangat signifikan antarprovinsi. Jumlah *merchant* bervariasi dari 81.000 hingga 7.732.000 unit, dengan deviasi standar yang tinggi. Ini menunjukkan bahwa penerapan QRIS terpusat di beberapa provinsi besar, sementara beberapa provinsi lainnya masih memiliki tingkat penggunaan yang jauh lebih rendah.



Variabel-variabel independen x_1 hingga x_7 juga menunjukkan pola sebaran yang beragam. PDRB (x_1), Total UMKM (x_6), dan Kepadatan Penduduk (x_5) menunjukkan rentang nilai yang besar, yang menandakan adanya ketimpangan dalam kapasitas ekonomi dan aktivitas bisnis di berbagai wilayah. Variabel sosial seperti Rata-Rata Lama Sekolah (x_2) dan Tingkat Urbanisasi (x_4) relatif lebih seragam, meskipun masih menunjukkan perbedaan antarprovinsi. Di sisi lain, indikator digital seperti Akses TIK (x_3) dan Persentase Pengguna Internet (x_7) menunjukkan bahwa penetrasi teknologi belum merata.

3.2 Regresi Model Global dengan OLS

Model regresi linear berganda dengan metode *Ordinary Least Square* (OLS) digunakan sebagai model global untuk menganalisis pengaruh variabel-variabel independen terhadap jumlah *merchant* QRIS. Model ini dibangun menggunakan 33 observasi dengan tujuh variabel bebas. Nilai estimasi hasil dari regresi dapat dilihat pada Tabel 3.

Tabel 3. Hasil OLS

Variabel	Estimasi	Std. error	t	P > t
const	1083545,4545	152128,6289	7,1226	0,0000
x_1	-80772,5857	-80772,5857	-0,2663	0,7922
x_2	107874,9410	202466,0815	0,5328	0,5989
x_3	-81419,0184	272929,0565	-0,2983	0,7679
x_4	86129,3082	397346,8249	0,2168	0,8302
x_5	864753,3224	291923,0669	2,9623	0,0066
x_6	1171975,2751	195595,3818	5,9918	0,0000
x_7	232650,5230	374854,8411	0,6206	0,5405

Berdasarkan hasil estimasi pada tabel 3, persamaan regresi linear yang terbentuk yaitu:

$$\hat{Y} = 1083545 - 80773x_1 + 107875x_2 - 81419x_3 + 86129x_4 + 864753x_5 + 1171975x_6 + 232651x_7$$

Dari hasil regresi juga akan dilakukan uji signifikansi simultan (uji F) untuk mengetahui apakah seluruh variabel independen secara bersama-sama berpengaruh terhadap variabel dependen. Berdasarkan hasil pengujian diperoleh nilai $F - statistic$ sebesar 14.80 dengan nilai $Prob(F - statistic)$ sebesar $1,80 \times 10^{-7}$. Karena nilai $Prob(F - statistic) < \alpha(0,1)$, maka dapat disimpulkan bahwa model regresi OLS signifikan secara simultan.

Uji signifikansi parsial dilakukan untuk mengetahui pengaruh masing-masing variabel independen terhadap jumlah *merchant* QRIS secara individual. Pengujian dilakukan pada tingkat signifikansi 10%. Variabel x_5 (Kepadatan Penduduk) memiliki nilai $p-value$ sebesar 0,0066 ($p < 0,1$), sehingga dinyatakan berpengaruh signifikan terhadap jumlah *merchant* QRIS. Variabel x_6 (Jumlah UMKM) memiliki nilai $p-value$ sebesar 0,0000 ($p < 0,1$), sehingga dinyatakan berpengaruh signifikan terhadap jumlah *merchant* QRIS.

Dominansi pengaruh jumlah UMKM (x_6) mengonfirmasi ketergantungan ekosistem QRIS pada sektor usaha mikro. Hal ini sejalan dengan (Widayani et al., 2022) yang menemukan bahwa terlepas dari adanya hambatan fungsional, UMKM tetap mengadopsi pembayaran digital sebagai strategi krusial untuk mempertahankan daya saing bisnis. Selain itu, signifikansi Kepadatan Penduduk (x_5) mendukung temuan (Mindawati & Nugroho, 2025), di mana tingginya kepadatan penduduk terbukti meningkatkan permintaan konsumsi rumah tangga secara signifikan, yang secara alami mendorong frekuensi transaksi dan kebutuhan *merchant*. Sebaliknya, Infrastruktur TIK (x_3) yang tidak signifikan mengindikasikan bahwa ketersediaan fisik saja tidak cukup sebagaimana dijelaskan (Fakriah et al., 2025), determinan utama adopsi kini lebih dipengaruhi oleh persepsi keamanan dan kepercayaan user dibandingkan sekedar aksesibilitas jaringan.

3.3 Uji Asumsi Klasik

3.3.1 Uji Normalitas Residual

Uji normalitas dilakukan menggunakan metode Shapiro-Wilk sesuai dengan persamaan (3) untuk memeriksa kesesuaian antara urutan residual yang diamati dengan distribusi normal. Berdasarkan hasil pengujian, diperoleh nilai $p-value$ sebesar $2,78 \times 10^{-7}$. Nilai tersebut kemudian dibandingkan dengan tingkat signifikansi $\alpha = 0,1$. Karena nilai $p-value$, maka H_0 ditolak, yang mengindikasikan bahwa residual tidak berdistribusi normal. Ketidaknormalan residual ini menjadi indikasi kuat adanya heterogenitas data antar provinsi yang tidak dapat ditangkap sepenuhnya oleh model global (OLS), sehingga diperlukan pendekatan analisis spasial lebih lanjut (Fotheringham et al., 2002).

3.3.2 Uji Multikolinearitas

Pengujian multikolinearitas dilakuakn dengan menggunakan *Variance Inflation Factor* (VIF) yang merupakan indikator seberapa besar varians koefisien regresi meningkat akibat kolinearitas. Hasil pengujian VIF dapat dilihat di Tabel 4.

Tabel 4. Hasil Perhitungan VIF

Variabel	VIF
PDRB per Kapita	3,855



Variabel	VIF
Lama Sekolah	1,718
Indeks TIK	3,121
Urban Rate	6,615
Kepadatan Penduduk	3,571
UMKM	1,603
Akses Internet	5,888

Berdasarkan Tabel 4, terlihat bahwa nilai VIF tertinggi terdapat pada variabel *urban rate* (6,615) dan akses internet (5,888). Meskipun kedua variabel ini memiliki nilai yang lebih tinggi dibandingkan variabel lainnya, seluruh nilai VIF yang diperoleh masih berada di bawah ambang batas yang ditetapkan, yaitu 10. Karena seluruh nilai $VIF \leq 10$ maka dapat disimpulkan bahwa tidak terjadi multikolinearitas antar variabel independen dan layak untuk dianalisis lebih lanjut.

3.3.3 Uji Heteroskedastisitas

Pengujian heteroskedastisitas dilakukan menggunakan uji Breusch–Pagan–Godfrey atau LM Test untuk memastikan apakah varians residual dalam model regresi bersifat konstan (homoskedastis) atau berubah-ubah. Berdasarkan hasil pengujian, diperoleh nilai statistik LM sebesar 10,47 dengan *p-value* sebesar 0,1062. Dengan menggunakan tingkat signifikansi 10%, nilai *p-value* tersebut lebih besar dari α sehingga hipotesis nol diterima. Hasil ini menunjukkan bahwa tidak terdapat heteroskedastisitas yang signifikan pada model regresi OLS, sehingga varians residual dapat dianggap konstan dan model layak digunakan sebagai model global sebelum dilakukan analisis spasial menggunakan AGWR.

3.3.4 Uji Independensi Residual

Pengujian independensi dilakukan untuk memastikan bahwa residual pada suatu lokasi tidak memiliki ketergantungan dengan residual di lokasi sekitarnya. Pengujian menggunakan statistik Moran's I dengan matriks pembobot spasial metode *Distance Band* dengan *threshold* 1200 km. Pemilihan nilai 1200 km didasarkan pada kriteria *Maximum Nearest Neighbor* untuk menjamin konektivitas seluruh observasi dalam matriks pembobot, sehingga tidak terdapat wilayah yang terisolasi. Secara geografis, jarak ini mengakomodasi interaksi ekonomi di Kawasan Timur Indonesia (khususnya Maluku dan Papua) yang memerlukan radius interaksi di atas 1000 km, serta merefleksikan realitas transportasi multimoda (laut dan udara) yang melampaui batasan fisik kepulauan (Miranti & Mendez, 2023).

Berdasarkan hasil pengujian, diperoleh nilai Moran's I sebesar $-0,09$ dengan *p-value* sebesar 0,092. Keputusan pengujian dilakukan dengan membandingkan nilai *p-value* dengan tingkat signifikansi $\alpha = 0,1$. Karena nilai *p-value* $0,092 < \alpha$, mengindikasikan adanya autokorelasi spasial pada residual. Adanya struktur spasial yang tertinggal pada residual menandakan bahwa model global (OLS) tidak mampu menangkap variasi spasial data secara menyeluruh.

3.4 Uji Asumsi Spasial

Uji spasial dilakukan untuk mengidentifikasi adanya heterogenitas spasial dan autokorelasi spasial yang menjadi dasar penentuan kelayakan penggunaan model regresi lokal. Pengujian ini mencakup uji heterogenitas spasial menggunakan Breusch–Pagan (BP) dan uji autokorelasi spasial menggunakan Moran's I.

Hasil uji heterogenitas spasial menggunakan uji Breusch–Pagan menghasilkan nilai *LM Statistic* sebesar 3,129 dengan *p-value* 0,209. Karena *p-value* $0,209 > \alpha$ (0,1), maka H_0 diterima, yang menunjukkan secara statistik global tidak terdeteksi adanya heterogenitas spasial yang signifikan pada parameter regresi.

Pengujian autokorelasi spasial dilakukan pada residual model OLS dan variabel dependen. Hasil uji menunjukkan nilai indeks Moran's I sebesar 0,704 dengan *p-value* 0,019, dimana nilai Moran's I yang bertanda positif (0,704) mengindikasikan bahwa distribusi residual membentuk pola pengelompokan. Karena nilai *p-value* $0,019 < \alpha$, maka terdapat autokorelasi spasial yang signifikan. Namun, pengujian Global Moran's I pada variabel dependen menggunakan *K-Nearest Neighbor* $k = 2$ menunjukkan nilai indeks 0,253 dengan *p-value* 0,065. Nilai ini signifikan pada taraf nyata α (0,1), yang mengkonfirmasi adanya *weak positive spatial autocorrelation* atau kecenderungan pengelompokan nilai yang serupa antar wilayah yang berdekatan.

Untuk memperdalam analisis, dilakukan pemetaan *Local Indicators of Spatial Association* (LISA). Hasil analisis LISA mendeteksi adanya pola *clustering* signifikan, yaitu:

- Klaster High-High (*Hotspot*):** Teridentifikasi di wilayah Jawa Barat dan Banten. Pola ini menunjukkan bahwa provinsi dengan adopsi QRIS tinggi dikelilingi oleh provinsi tetangga yang juga memiliki adopsi tinggi. Fenomena ini mencerminkan adanya efek tular (*spillover effect*) dari pusat pertumbuhan ekonomi digital yang seringkali terbentuk akibat adanya interaksi ekonomi yang intensif antar wilayah (Anselin, 1995).
- Klaster Low-Low (*Coldspot*):** Teridentifikasi di wilayah Jawa Tengah, DIY, Jawa Timur, dan Bali. Pola ini mengindikasikan bahwa provinsi dengan jumlah *merchant* QRIS relative rendah (dibandingkan *hotspot*) bertentangan dengan wilayah yang juga memiliki karakteristik serupa.

Meskipun uji heterogenitas global (BP) tidak signifikan, keberadaan autokorelasi spasial pada variabel dependen dan temuan klaster LISA, serta hasil uji normalitas residual yang tidak terpenuhi, memberikan bukti kuat adanya ketidakstabilan spasial lokal. Model global seringkali gagal menangkap variasi parameter lokal yang bersifat subtil,


sehingga pemodelan lokal seperti *Geographically Weighted Regression* tetap diperlukan untuk mengidentifikasi faktor-faktor yang berpengaruh secara spesifik di setiap lokasi (Fotheringham et al., 2002).

3.5 Pemodelan *Adaptive Geographically Weighted Regression*

Segala perhitungan pada tahap ini menggunakan *module* mgwr dan menggunakan *backend* Google Compute Engine Python 3 di Google Colab untuk memastikan keadilan dalam perhitungan. Tahap awal estimasi model dilakukan dengan menghitung matriks jarak antarprovinsi. Karakteristik geografis Indonesia yang berbentuk kepulauan dan memiliki bentang wilayah yang luas, penggunaan jarak *Euclidean* berpotensi menghasilkan bias. Oleh karena itu, penelitian ini menggunakan formula Haversine untuk menghitung jarak geodesik antar *centroid* provinsi sehingga bobot spasial yang terbentuk lebih merepresentasikan kedekatan geografis yang sesungguhnya (Meliyana et al., 2025).

Tahap berikutnya adalah penggunaan matriks pembobot spasial menggunakan *Adaptive Bisquare Kernel*. Pemilihan kernel ini didasarkan pada kemampuannya dalam menyesuaikan *bandwidth* sesuai dengan kepadatan observasi, wilayah dengan konsentrasi data tinggi (misalnya Jawa) akan memperoleh *bandwidth* lebih sempit, sedangkan wilayah dengan observasi lebih jarang memperoleh *bandwidth* lebih lebar. Pendekatan ini dilakukan untuk mengatasi ketidakseimbangan distribusi unit analisis antarwilayah (Sugasawa & Murakami, 2021).

Penentuan *bandwidth* optimal dilakukan melalui cara iteratif dengan kriteria *Cross-Validation* (CV) dan metode pencarian *golden search*. *Bandwidth* yang meminimalkan nilai CV dipilih karena menghasilkan performa prediktif terbaik (Lee & Park, 2025). Hasil estimasi menunjukkan *bandwidth* optimal sebesar 16, yang mengidentifikasi bahwa estimasi parameter untuk suatu provinsi secara efektif memanfaatkan informasi dari 16 provinsi terdekat. Setelah *bandwidth* optimal diperoleh, dilakukan estimasi parameter lokal (β) untuk setiap provinsi. Distribusi spasial dari nilai koefisien regresi untuk masing-masing variabel independen tersebut divisualisasikan secara geografis pada gambar 3 berikut:



Gambar 3. Peta Sebaran Parameter Lokal Model AGWR di Indonesia

Visualisasi pemetaan pada gambar 3 memperlihatkan pola heterogenitas spasial yang nyata di seluruh wilayah Indonesia. Gradasi warna yang bervariasi antarprovinsi pada setiap peta variabel mengindikasikan bahwa setiap prediktor memiliki besaran pengaruh (*magnitude*) yang tidak seragam terhadap variabel respon di setiap lokasi. Wilayah dengan warna yang lebih pekat menunjukkan nilai koefisien yang berbeda secara intensitas dibandingkan wilayah dengan warna yang lebih terang, yang mengonfirmasi bahwa dampak dari variabel-variabel bersifat lokal dan bergantung pada karakteristik spesifik masing-masing provinsi.

Tahap perbandingan antara model regresi global OLS dan model lokal *Adaptive Geographically Weighted Regression* (AGWR) dilakukan menggunakan statistik uji Leung's F-test. Berdasarkan hasil perhitungan, diberikan nilai $F_{hit} = 1.90$ dan $F_{tabel} = 2.65$ atau $2.65 > 1.90$ maka H_0 gagal ditolak yang menunjukkan bahwa peningkatan model AGWR terhadap model OLS belum signifikan secara inferensial. Hasil ini berkaitan dengan karakteristik data dan model yang digunakan, di mana jumlah observasi relatif terbatas ($n = 33$) dibandingkan dengan kompleksitas model AGWR yang memiliki jumlah parameter efektif sebesar 24,06, sehingga menghasilkan derajat bebas penyebut yang kecil ($df_2 = 6,59$). Dalam kondisi tersebut, sensitivitas uji inferensial formal untuk mendeteksi perbedaan model menjadi terbatas. Oleh karena itu, evaluasi terhadap kinerja model AGWR dalam penelitian ini tidak hanya didasarkan pada hasil Leung's F-test, tetapi juga mempertimbangkan variasi signifikansi lokal yang dihasilkan serta perbandingan metrik AIC, SSE, R^2 , dan *Adjusted R²* antar kedua model yang memberikan gambaran lebih komprehensif mengenai kemampuan AGWR dalam merepresentasikan heterogenitas spasial dibandingkan model regresi global.

3.6 Uji Parsial Parameter Model AGWR

Uji parsial parameter model AGWR dilakukan untuk mengevaluasi kontribusi relatif dari masing-masing parameter regresi pada tingkat spasial yang berbeda. Hal ini memungkinkan pemahaman yang lebih mendalam tentang bagaimana variabel independen berkontribusi secara lokal dalam menjelaskan variasi spasial fenomena yang diamati. Uji parsial parameter dilakukan berdasarkan uji T dengan taraf signifikansi $\alpha = 10$. Pada pengujian parsial parameter model AGWR akan diperoleh nilai T_{hit} yang akan dibandingkan dengan nilai T_{tabel} , di mana nilai T_{tabel} diperoleh nilai sebesar 1.70814. Kriteria pengambilan keputusan pada uji parsial parameter yaitu jika $|T_{hit}| > T_{tabel}$, maka variabel independen tersebut berpengaruh secara signifikan terhadap model. Tabel 5 berikut menunjukkan variabel yang signifikan dalam pemodelan *merchant QRIS* di 33 provinsi di Indonesia.

Tabel 5. Variabel Signifikan di 33 Provinsi di Indonesia

Provinsi	Variabel Signifikan	Provinsi	Variabel Signifikan	Provinsi	Variabel Signifikan
Aceh	x_6	Jawa Barat	x_2, x_3, x_6, x_7	Kalimantan Timur	x_6
Sumatera Utara	x_6	Jawa Tengah	x_1, x_2, x_3, x_5, x_6	Sulawesi Utara	-
Sumatera Barat	x_6	DI Yogyakarta	x_1, x_2, x_3, x_5, x_6	Sulawesi Tengah	-
Riau	x_6	Jawa Timur	$x_1, x_2, x_3, x_4, x_5, x_6$	Sulawesi Selatan	x_6
Jambi	x_6	Banten	$x_1, x_2, x_3, x_5, x_6, x_7$	Sulawesi Tenggara	x_6
Sumatera Selatan	x_6	Bali	x_5, x_6	Gorontalo	-
Bengkulu	x_6	Nusa Tenggara Barat	x_6	Sulawesi Barat	x_6
Lampung	x_4, x_5, x_6	Nusa Tenggara Timur	x_6	Maluku	-
Kep. Bangka Belitung	x_6	Kalimantan Barat	x_5, x_6	Maluku Utara	-
Kep. Riau	x_6	Kalimantan Tengah	x_5, x_6	Papua Barat	-
DKI Jakarta	x_1, x_2, x_3, x_6, x_7	Kalimantan Selatan	x_6	Papua	-

Berdasarkan Tabel 5, terlihat bahwa pengaruh masing-masing variabel independen terhadap jumlah *merchant* QRIS menunjukkan pola yang bervariasi antarprovinsi. Secara umum, variabel UMKM (x_6) muncul sebagai variabel yang paling konsisten signifikan di sebagian besar wilayah Indonesia, diantaranya seperti provinsi - provinsi di Sumatra, Jawa, Kalimantan, Nusa Tenggara, dan Sulawesi. Selain itu, provinsi-provinsi di pulau Jawa seperti DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, dan Banten menunjukkan signifikansi pada lebih banyak variabel yaitu masing-masing mulai dari 4 hingga 6 variabel. Sebaliknya, beberapa provinsi di kawasan timur Indonesia seperti Sulawesi Utara, Sulawesi Tengah, Gorontalo, Maluku, Maluku Utara, Papua Barat, dan Papua tidak menunjukkan adanya variabel signifikan. Kondisi ini mengindikasikan bahwa penyebaran *merchant* QRIS di wilayah tersebut tidak sepenuhnya dijelaskan oleh variabel sosial-ekonomi yang digunakan, sehingga kemungkinan dipengaruhi faktor struktural lain. Secara keseluruhan, AGWR menunjukkan bahwa variabel-variabel yang berpengaruh signifikan terhadap jumlah *merchant* QRIS cenderung terkluster berdasarkan kedekatan geografis. Temuan ini sejalan dengan Hukum Pertama Geografi yang menyatakan bahwa “segala sesuatu saling berkaitan, tetapi sesuatu yang berdekatan memiliki keterkaitan yang lebih besar” (McKercher, 2018). Dengan demikian, variasi koefisien pada model AGWR tidak hanya menggambarkan adanya *spatial non-stationarity*, tetapi juga memperlihatkan keteraturan spasial yang memperkuat bahwa fenomena *merchant* QRIS turut dipengaruhi oleh faktor kedekatan geografis.

3.7 Pemilihan Model Terbaik

Pemilihan model terbaik antara regresi OLS dan model AGWR dilakukan dengan cara membandingkan nilai *Akaike Information Criterion* (AIC), *Sum Square Error* (SSE), Koefisien Determinasi (R^2), dan *Adjusted R^2*. Model yang lebih baik adalah model yang memiliki nilai AIC dan SSE terkecil serta nilai R^2 dan *Adjusted R^2* terbesar atau yang paling mendekati 1. Tabel 6 menunjukkan perbandingan nilai AIC, SSE, R^2 , dan *Adjusted R^2* antara model regresi OLS dan AGWR.

Tabel 6. Perbandingan Model Regresi OLS dan AGWR

Model	AIC	SSE	R^2	Adj R^2
Regresi OLS	1003,417	$1,91 \times 10^{13}$	0,806	0,751
<i>Adaptive Geographically Weighted Regression</i> (AGWR)	967,981	$2,32 \times 10^{12}$	0,976	0,905

Berdasarkan tabel 6, model *Adaptive Geographically Weighted Regression* (AGWR) menunjukkan kinerja yang lebih baik dibandingkan model regresi global OLS. Hal ini terlihat dari nilai *Sum Square Error* (SSE) pada model AGWR yang jauh lebih kecil ($2,32 \times 10^{12}$) dibandingkan dengan model OLS ($1,91 \times 10^{13}$), sehingga menunjukkan bahwa AGWR mampu meminimalkan galat prediksi dengan lebih efektif. Selain itu, nilai AIC pada AGWR (967,981) lebih rendah daripada OLS (1003,417), yang menandakan bahwa model AGWR memberikan keseimbangan yang lebih baik antara *goodness of fit* dan kompleksitas model. Dari sisi koefisien determinasi, nilai R^2 AGWR (0,976) jauh lebih tinggi dibandingkan nilai R^2 OLS (0,806). Setelah memperhitungkan kompleksitas model, *adjusted R^2* AGWR tetap lebih tinggi (0,905) daripada *adjusted R^2* OLS (0,751), sehingga menunjukkan bahwa peningkatan performa AGWR bukan hanya disebabkan oleh jumlah parameter yang lebih banyak, tetapi memang mencerminkan kemampuan model yang lebih baik dalam menjelaskan variasi spasial. Temuan tersebut mengindikasikan adanya ketidakstasioneran geografis yang tidak dapat ditangkap oleh model global. Dengan demikian, AGWR dipilih sebagai model terbaik karena mampu menangkap variasi lokal secara lebih akurat dan memberikan performa statistik yang lebih unggul dibandingkan OLS.



3.8 Pembahasan

Dari hasil dan pembahasan mengindikasikan bahwa hubungan antara variabel-variabel independen dan jumlah merchant QRIS tidak bersifat homogen secara geografis. Model OLS hanya mampu menangkap hubungan rata-rata secara nasional sehingga kurang sensitif terhadap variasi karakteristik wilayah yang beragam di Indonesia. Sebaliknya, AGWR memungkinkan setiap wilayah memiliki koefisien regresi lokal yang berbeda, sehingga mampu menangkap ketidakstasioneran spasial yang tidak dapat direpresentasikan oleh model global. Variasi koefisien lokal yang dihasilkan AGWR menunjukkan bahwa pengaruh masing-masing variabel berubah antar zona geografis.

Variabel yang berpengaruh signifikan terhadap jumlah merchant QRIS juga berbeda antar provinsi. Variabel jumlah UMKM merupakan faktor yang paling konsisten dan signifikan di hampir seluruh wilayah Indonesia yang menegaskan peran sentral UMKM dalam mendorong adopsi QRIS secara nasional. Di wilayah Jawa dan provinsi dengan tingkat aktivitas ekonomi tinggi, variabel pendidikan, infrastruktur TIK, serta PDRB cenderung signifikan secara simultan yang mencerminkan kompleksitas faktor pendorong adopsi QRIS di wilayah maju. Sebaliknya, di banyak provinsi luar Jawa dan kawasan timur Indonesia hanya sedikit variabel yang signifikan, bahkan pada beberapa provinsi tidak ditemukan variabel yang signifikan secara statistik yang mengindikasikan bahwa adopsi QRIS di wilayah tersebut masih dipengaruhi oleh faktor-faktor struktural di luar variabel yang dianalisis. Temuan ini menegaskan bahwa kebijakan pengembangan QRIS perlu disesuaikan secara regional dengan fokus pada penguatan UMKM secara luas dan pendekatan yang lebih spesifik sesuai karakteristik lokal masing-masing wilayah.

Dari hasil ini dapat dijadikan perumusan kebijakan pengembangan sistem pembayaran digital. Pendekatan kebijakan yang bersifat seragam secara nasional berpotensi kurang efektif karena tidak mempertimbangkan variasi kondisi regional. Di wilayah dengan tingkat adopsi QRIS yang masih rendah, kebijakan dapat difokuskan pada penguatan infrastruktur digital, peningkatan literasi teknologi, dan pemberdayaan UMKM. Sebaliknya, di wilayah dengan tingkat adopsi yang sudah tinggi, strategi dapat diarahkan pada peningkatan kualitas layanan, interoperabilitas sistem, dan inovasi penggunaan QRIS dalam ekosistem ekonomi digital.

4. KESIMPULAN

Berdasarkan hasil penelitian mengenai analisis spasial dan variasi lokal jumlah merchant QRIS di Indonesia menggunakan pendekatan *Adaptive Geographically Weighted Regression* (AGWR), dapat disimpulkan bahwa penyebaran merchant QRIS menunjukkan pola yang tidak homogen dan dipengaruhi secara berbeda oleh karakteristik sosial-ekonomi setiap wilayah. Model AGWR secara konsisten memberikan performa yang lebih baik dibandingkan model regresi OLS, ditunjukkan oleh nilai AIC (967,981) dan SSE ($2,32 \times 10^{12}$) AGWR yang lebih rendah dari AIC (1003,417) dan SSE ($1,91 \times 10^{13}$) regresi OLS. Performa AGWR juga didukung oleh nilai R^2 (0,976) dan *adjusted R*² (0,905) yang secara signifikan lebih tinggi dibandingkan nilai R^2 (0,806) dan *adjusted R*² (0,751) pada regresi OLS, sehingga menunjukkan bahwa AGWR lebih mampu menangkap variasi spasial yang tidak dapat dijelaskan oleh model global. Hasil estimasi koefisien lokal menunjukkan bahwa variabel jumlah UMKM muncul sebagai faktor paling stabil dan signifikan di sebagian besar provinsi, sementara variabel seperti PDRB per kapita, rata-rata lama sekolah, akses dan infrastruktur TIK, *urban rate*, kepadatan penduduk, dan akses internet hanya signifikan pada provinsi-provinsi tertentu, khususnya di provinsi-provinsi pulau Jawa. Sebaliknya, provinsi-provinsi di Papua, Maluku, dan sebagian wilayah Indonesia Timur lainnya tidak menunjukkan variabel yang signifikan, yang mengindikasikan bahwa penyebaran merchant QRIS di wilayah tersebut kemungkinan lebih dipengaruhi oleh faktor lain yang belum tercakup dalam model ini. Keterbatasan penelitian ini terletak pada cakupan wilayah analisis yang hanya mencakup 33 provinsi dari total 38 provinsi di Indonesia. Hal ini disebabkan karena keterbatasan ketersediaan data yang bersifat tidak terhindarkan, khususnya pada provinsi-provinsi hasil pemekaran terbaru di Papua, yaitu Papua Barat Daya, Papua Selatan, Papua Tengah, dan Papua Pegunungan, yang belum memiliki data lengkap terkait jumlah merchant QRIS, indeks akses dan infrastruktur TIK, serta *urban rate* pada periode penelitian. Selain itu, keterbatasan data *urban rate* pada Provinsi Kalimantan Utara juga menyebabkan provinsi tersebut tidak dapat diikutsertakan dalam analisis. Penelitian selanjutnya dapat ditingkatkan dengan menggunakan data yang lebih komprehensif agar seluruh provinsi di Indonesia dapat dianalisis, serta mengeksplorasi variabel independen lain yang lebih mampu menangkap pola khusus di wilayah Indonesia Timur seperti keterbatasan infrastruktur digital, preferensi metode pembayaran, ataupun tingkat literasi keuangan.

REFERENCES

- Anselin, L. (1995). Local Indicators of Spatial Association—LISA. *Geographical Analysis*, 27(2), 93–115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Ardasanti, A., Kusumaningrum, R. A., Hikmah, H., Nurhidayanti, S., Abubakar, H., Fadel, F., & Pertiwi, I. (2025). Analisis Efektivitas QRIS dalam Meningkatkan Inklusi Keuangan UMKM Makassar. *Journal of Economic, Bussines and Accounting (COSTING)*, 8(4), 2215–2224. <https://doi.org/10.31539/tvwwwr95>
- Bani Rachmad, A. A., & Raharjo, M. (2023). 'QRIS Cross Border' as Digital Financial Inclusion Acceleration in Southeast Asia. *Global Local Interactions: Journal of International Relations*, 3(1), 151–161. <https://doi.org/10.22219/gli.v3i1.25234>



- Birigozzi, A., De Silva, C., & Luitel, P. (2025). Digital Payments and GDP Growth: A Behavioural Quantitative Analysis. *Research in International Business and Finance*, 75, 102768. <https://doi.org/10.1016/j.ribaf.2025.102768>
- Fakriah, R. A., Alfahito, M. D., & Mardiyani. (2025). What Drives Digital Payment Adoption? Examining the Role of Ease of Use, Security, and Trust. *Journal of Enterprise and Development*, 7(1), 101–113. <https://doi.org/10.20414/jed.v7i1.12863>
- Fotheringham, A. S., Brunson, C., & Charlton, M. (2002). *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*. Wiley.
- Haryanti, P. (2024). Hubungan Penggunaan QRIS dengan Pengembangan Ekonomi Digital UMKM di KMGD Jombang. *Jurnal Ilmiah Manajemen Dan Bisnis (JIMBis)*, 3(1), 28–41. <https://doi.org/10.24034/jimbis.v3i1.6170>
- Hocking, R. R. (2003). *Methods and Applications of Linear Models: Regression and the Analysis of Variance* (1st ed.). Wiley. <https://doi.org/10.1002/0471434159>
- Huang, Z., Li, S., Peng, Y., & Gao, F. (2023). Spatial Non-Stationarity of Influencing Factors of China's County Economic Development Base on a Multiscale Geographically Weighted Regression Model. *ISPRS International Journal of Geo-Information*, 12(3), 109. <https://doi.org/10.3390/ijgi12030109>
- Kim, J. H., & Choi, I. (2021). Choosing the Level of Significance: A Decision-theoretic Approach. *Abacus*, 57(1), 27–71. <https://doi.org/10.1111/abac.12172>
- Lee, H., & Park, Y. W. (2025). Integrated subset selection and bandwidth estimation algorithm for geographically weighted regression. *Pattern Recognition*, 165, 111589. <https://doi.org/10.1016/j.patcog.2025.111589>
- 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>
- Mbete, R. L. K., Miswanto, Biyanto, F., & Siregar, B. (2025). The Spatial Lag X Method Using Three Types of Distance Weighting in Food Security Data Analysis in Central Sulawesi. *Indonesian Journal of Contemporary Multidisciplinary Research*, 4(1), 1–10. <https://doi.org/10.55927/modern.v4i1.13266>
- McKercher, B. (2018). The Impact of Distance on Tourism: A Tourism Geography Law. *Tourism Geographies*, 20(5), 905–909. <https://doi.org/10.1080/14616688.2018.1434813>
- Meliyana, S. M., Ahmar, A. S., & Rahman, A. (2025). Geographically Weighted Regression (GWR) Modeling in Identifying Factors Affecting the Gender Empowerment Index in Indonesia. *Daengku: Journal of Humanities and Social Sciences Innovation*, 5(4), 539–546. <https://doi.org/10.35877/454RI.daengku4449>
- Mindawati, B., & Nugroho, R. Y. Y. (2025). Sustainable Economic Development and Digital Payments on Public Consumption Demand: Evidence from Indonesia. *Jurnal Ekonomi Dan Studi Pembangunan*, 17(2), 151–165.
- Miranti, R. C., & Mendez, C. (2023). Social and Economic Convergence Across Districts in Indonesia: A Spatial Econometric Approach. *Bulletin of Indonesian Economic Studies*, 59(3), 421–445. <https://doi.org/10.1080/00074918.2022.2071415>
- Miranti, R. C., Siregar, S. I., & Willyana, A. B. (2024). How Does Inclusion of Digital Finance, Financial Technology, and Digital Literacy Unlock the Regional Economy Across Districts in Sumatra? A Spatial Heterogeneity and Sentiment Analysis. *GeoJournal*, 89(4), 136. <https://doi.org/10.1007/s10708-024-11110-w>
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to Linear Regression Analysis* (Sixth edition). Wiley.
- Moran, P. A. P. (1950). A Test for the Serial Independence of Residuals. *Biometrika*, 37(1–2), 178–181. <https://doi.org/10.1093/biomet/37.1-2.178>
- Priya, G. M., & Shalini, P. (2025). A Comparative Study on Urban and Rural Areas Adopting Digital Payment System. *TIJER - INTERNATIONAL RESEARCH JOURNAL*, 12(3), 1–3.
- Shapiro, S. S., & Wilk, M. B. (1965). An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, 52(3–4), 591–611. <https://doi.org/10.1093/biomet/52.3-4.591>
- Shinta, S. (2024). Pengaruh Urbanisasi Terhadap Perubahan Kondisi Sosial dan Ekonomi di Indonesia. *Jurnal Swarnabhumi: Jurnal Geografi Dan Pembelajaran Geografi*, 9(1), 47–55. <https://doi.org/10.31851/swarnabhumi.v9i1.10068>
- Sugasawa, S., & Murakami, D. (2021). Spatially Clustered Regression. *Spatial Statistics*, 44, 100525. <https://doi.org/10.1016/j.spasta.2021.100525>
- Swastika, Y., Maksar, M. S., & Cahyani, E. A. (2024). Factors Affecting the Use of Digital Payments in Indonesia: Evidence from Global Findex Database 2021. *ECOTECHNOPRENEUR: Journal Economics, Technology and Entrepreneur*, 3(3), 162–178. <https://doi.org/10.62668/ecotechnopreneur.v3i03.1254>
- Tangka, F. E., Hatidja, D., & Weku, W. Ch. D. (2024). Geographically Weighted Regression Modeling with Adaptive Gaussian Kernel Weighting on GRDP in Indonesia. *Jurnal Ilmiah Sains*, 110–119. <https://doi.org/10.35799/jis.v24i2.50366>
- Widayani, A., Fiernaningsih, N., & Herijanto, P. (2022). Barriers to Digital Payment Adoption: Micro, Small and Medium Enterprises. *Management & Marketing*, 17(4), 528–542. <https://doi.org/10.2478/mmcks-2022-0029>