

OPTIMALISASI GeoDa DALAM PEMODELAN DAN PEMETAAN PENYAKIT DI KOTA BANDUNG

I Gede Nyoman Mindra Jaya, Bertho Tantular, dan Zulhanif
Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Padjadjaran
e-mail: mindra@unpad.ac.id

ABSTRAK,

Pemodelan dan pemetaan penyakit dapat diadopsi dalam mengembangkan *early warning system* penyakit. Melalui pemodelan dan pemetaan, praktisi dan pihak-pihak yang berkepentingan akan dapat melakukan prediksi awal terhadap lokasi-lokasi yang memiliki resiko tinggi suatu penyakit. Melalui informasi ini, pihak-pihak yang berkepentingan khususnya dinas kesehatan akan mampu menen strategi yang tepat-efisien dan efektif. GeoDa memfasilitasi kebutuhan praktisi dalam melakukan pemodelan dan pemetaan penyakit namun untuk dapat mengoptimalkan manfaat dari GeoDa praktisi harus memiliki pemahaman yang baik terhadap berbagai metode khususnya statistika yang mendasari perhitungan dalam setiap menu GeoDa khususnya dalam pemodelan dan pemetaan karena software ini memberikan berbagai alternative model dan pemetaan dengan hasil yang berbeda. Sehingga koding ini dapat menyebabkan kebingungan bagi praktisi yang belum memahami dengan baik dasar-dasar statistika yang digunakan. Tulisan ini menjelaskan tahapan dan statistika yang digunakan GeoDa dalam menghasilkan *output* dalam pemodelan dan pemetaan.

Kata kunci: Geoda, Pemodelan, Pemetaan, Statistika

ABSTRACT,

Modeling and mapping of diseases can be adopted in developing early warning systems for diseases. Through modeling and mapping, practitioners and interested parties will be able to make initial predictions of locations that have a high risk of an illness. Through this information, interested parties, especially the health department, will be able to find the right strategies that are efficient and effective. GeoDa facilitates practitioners' needs in conducting disease modeling and mapping but to be able to optimize the benefits of GeoDa practitioners must have a good understanding of various methods, especially statistics that underlie calculations in each GeoDa menu, especially in modeling and mapping because this software provides various alternative models and mapping with different results. So that this can cause confusion for practitioners who do not understand well the basics of statistics used. This paper describes the stages and statistics used by GeoDa in producing output in modeling and mapping.

Key words: Geoda, Modeling, Mapping, Statistics

PENDAHULUAN

Infeksi penyakit memiliki dampak serius tidak hanya bagi kesehatan namun juga pada kesejahteraan rumah tangga, bahkan lebih jauh lagi mengganggu per-ekonomian suatu negara (Jaya dkk, 2017; WHO, 2009). Berbagai jenis Penyakit telah memberikan dampak yang sangat buruk bagi masyarakat khususnya penyakit menular diantaranya Demam Berdarah, Acquired Immuno Deficiency Syndrome (AIDS), influenza, Tuberkulosis, Hepatitis, Kolera, Polio, dan masih banyak jenis penyakit lainnya.

Untuk individu, masalah kesehatan bisa berkisar dari gangguan kecil sampai mati. Namun, tidak hanya korban tetapi juga anggota keluarga mereka terpengaruh jika mereka jatuh sakit (misalnya, karena mereka kehilangan waktu untuk bekerja yang artinya kehilangan penghasilan). Implikasi lainnya adalah pengeluaran bertambah karena harus membayar biaya pengobatan. Terjangkit penyakit juga dapat menyebabkan hilangnya rekreasi dan juga libur dari sekolah. Gangguan lain adalah pembatasan pergerakan orang untuk mencegah penyebaran penyakit (Jaya dkk, 2017).

Mengingat dampaknya pada kesejahteraan kesejahteraan dan adanya peningkatan kejadian yang ekstrim karena perubahan iklim, meningkatkan kepadatan penduduk, mobilitas tinggi, perilaku hidup masyarakat,

kejadian dan penyebaran penyakit harus menjadi perhatian serius pemerintah baik pusat maupun daerah. Penelitian pola penyebaran penyakit telah banyak dilakukan (Anderson and Ryan, 2017; Arab, 2015; (Jaya dkk, 2016) namun metode dan alat yang dipergunakan sulit dipahami oleh praktisi sehingga penelitian hanya menghasilkan produk artikel dalam jurnal baik nasional maupun internasional namun tidak memberikan dampak nyata pada pengendalian penyakit.

Kota Bandung adalah salah satu kota di Jawa Barat yang memiliki permasalahan serius dalam hal pengendalian penyebaran Penyakit seperti demam berdarah, TB Paru, HIV dan Penyakit lainnya.

Pengendalian penyebaran penyakit tidak dapat dilakukan dengan cara-cara standar namun harus melakukan suatu inovasi dengan menggunakan pendekatan metodologis yang tentunya dapat diimplementasikan dalam aspek praktis.

Kemampuan melakukan pemodelan dan pemetaan Penyakit dapat membantu dalam penanggulangan Penyakit melalui deteksi dini lokasi-lokasi yang beresiko tinggi (Liu, dkk. 2017). Pemodelan dan pemetaan merupakan pendekatan statistik yang dapat dimanfaatkan oleh pengambil kebijakan dalam memformulasikan tindakan yang dapat dilakukan guna menekan penyebaran, angka kasus penyakit (Lee dan Lawson, 2015).

Pemodelan dan pemetaan penyakit seringkali diabaikan dalam upaya penanggulangan Penyakit karena adanya persepsi bahwa pemodelan memiliki tingkat kesulitan yang tinggi karena memerlukan kemampuan statistika dan komputasi yang tinggi.

Namun pendapat ini tidak sepenuhnya benar, berbagai model sederhana dapat diaplikasikan dalam upaya mengidentifikasi lokasi beresiko tinggi dengan bantuan software open source.

Makalah ini menyajikan teknik analisis data dalam pemetaan dan pemodelan Penyakit yang dapat dimanfaatkan oleh praktisi yang memiliki kemampuan statistika terbatas.

Salah satu software yang dapat dimanfaatkan untuk tujuan tersebut adalah GoDA. Software ini dirancang untuk memudahkan para praktisi dalam melakukan pemodelan dan pemetaan data spasial diantaranya penyeberan Penyakit. Sehingga penelitian ini bertujuan:

1. Memberikan gambaran metodologis tentang optimalisasi GeoDA dalam pemodelan dan pemetaan Penyakit
2. Menjelaskan tahapan pemodelan menggunakan GeoDA

METODE

Analisis Data Spasial: Data geographi atau spasial memiliki peran penting dalam kehidupan dari hal yang paling sederhana sampai yang paling kompleks. Hal yang paling sederhana adalah alamat tempat tinggal yang memuat informasi spasial seperti kode pos. Informasi tambang yang meliputi koordinat lokasi kedalaman merupakan contoh dari pemanfaatan data spasial.

Sehingga data spasial dapat dimaknai sebagai segala sesuatu yang berkaitan dengan ruang kebumihan yang ditandai oleh atribut geographis seperti koordinat lokasi dan yang lainnya sehingga Geographical Information System (GIS) memiliki peran penting dalam studi spasial (Lloyd, 2010).

Explorasi Data Spasial dengan GeoDA: Software GeoDa pertama kali diperkenalkan oleh Luc Anselin tahun 2002. Software ini dikembangkan dengan tujuan untuk memfasilitasi eksplorasi dan analisis data spasial dari hal yang sederhana sampai pemodelan yang kompleks (Anselin dkk, 2006).

Software ini menekankan pada kemampuan untuk visualisasi map seperti outlier maps, smoothing rate maps, cartogram map, dan map animasi). Explorasi data meliputi grafik statistic, parallel coordinates plot, conditional plots) dan eksplorasi khusus untuk spasial data. Software ini juga dirancang untuk mampu melakukan perhitungan spatial autokorelasi baik yang univariate ataupun yang bivariate. GeoDa juga didesain mampu menganalisis data input berupa shape file dari coordinate poin dan juga polygon dan koordinat centroid. Software ini juga memiliki fasilitas untuk membuat matrik bobot spasial menurut kriteria contiguity, distance, dan juga k-nearest neighbor. Model

spatial regression juga terfasilitasi oleh GeoDa. Software ini dapat dioperasikan pada sistem operasi Windows, IOS dan juga Linux (Anselin L. , 2003).

Installing GeoDa

Installing GeoDa dapat dilakukan secara langsung dengan terlebih dahulu mendownload mentahan dari GeoDa dari website <https://geodacenter.github.io/>. GeoDa memiliki menu seperti yang disajikan pada Tabel 1.

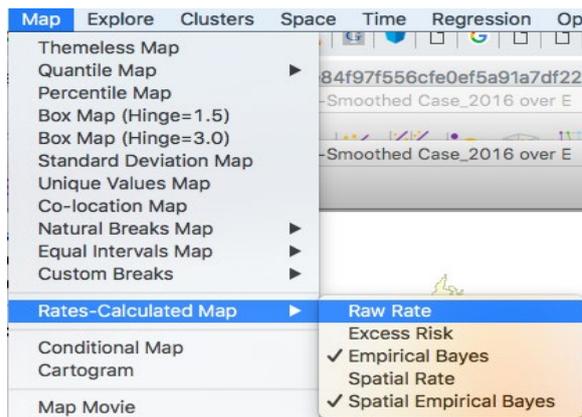
Tabel 1. Menu GeoDa

Kategori	Fungsi
Data Input	<ul style="list-style-type: none"> • Membaca format file data spasial (didukung oleh OGR) • Menghubungkan ke basis data spasial • Menghubungkan ke layanan fitur web (WFS) • Memuat data dari cartodb • Memuat data menggunakan project file • Menggabungkan table
Data Export	<ul style="list-style-type: none"> • Mengekspor data ke format yang berbeda • Ekspor pengamatan yang dipilih
Spatial Data Creation	<ul style="list-style-type: none"> • Titik spasial koordinat x-y • Titik spasial dari poligon centroid • Titik spasial dari pusat rata-rata poligon
Data Query	<ul style="list-style-type: none"> • Import peta • Menghubungkan data based dengan peta • Desain Query • Menciptakan variabel indikator • Menambahkan / menghapus variabel
Variabel transformation	<ul style="list-style-type: none"> • Transformasi (log, exp, dan lainnya) aljabar variabel • Nomor acak • Permutasi pengamatan • Menciptakan variabel lag spasial
Choropleth Mapping	<ul style="list-style-type: none"> • Peta Quantile • Peta Percentile • Natural break map • Equal interval map • Custom break • Co-location map
Statistical Maps	<ul style="list-style-type: none"> • Peta standar deviasi • Peta kotak • Peta persentil • Kartogram • Animasi
Smoothed Rate Maps	<ul style="list-style-type: none"> • Raw rate • Excess rate • Empirical Bayes • Spatial rate • Spatial empirical Bayes
Exploratory Data Analysis	<ul style="list-style-type: none"> • Histogram • Square plot • Scatter plot • Scatter lowess matriks plot • Bubble plot • 3D Scatter plot • Pparallel plot • Conditional plot

Model Pemetaan Penyakit

Pemodelan dan pemetaan penyakit umumnya menggunakan data cacah atau counting dalam menyatakan angka kasus (y) dan melibatkan data ukuran populasi (N) sebagai pembanding (Lawson, 2013; Lawson, 2006; Jaya dkk, 2014). Terdapat beberapa model dan ukuran yang digunakan dalam pemetaan penyakit yaitu: raw rate, excess rate, empirical Bayes, Spatial rate, Spatial empirical Bayes (Anselin, 2018). Setiap model ini memiliki asumsi nya masing-masing dan pemilihan model ini harus didukung oleh argumentasi statistic dan praktis.

Gambar 1. Menu map dalam GeoDa



Raw Rate: Merupakan model paling dasar dalam mengukur risiko suatu penyakit. Model ini diperoleh dengan rumusan yang sangat sederhana yaitu membagi angka kasus (y) dengan ukuran populasi berisiko (N) pada periode tertentu.

$$\hat{\pi}_i = \frac{y_i}{N_i}; i = 1, \dots, n$$

dengan $\hat{\pi}_i$ menyatakan taksiran *raw rate*, y_i menyatakan angka kasus dan N_i menyatakan ukuran populasi berisiko pada lokasi ke- i . Namun, ukuran ini tidak dapat digunakan untuk membandingkan risiko satu lokasi dengan lokasi lainya dikarenakan ukuran populasi setiap lokasi cenderung berbeda.

Excess Risk: Juga dikenal dengan standardized morbidity/mortality ratio (SMR). Melalui ukuran ini, dapat dilakukan perbandingan antara risiko pada satu lokasi dengan lokasi lainnya. SMR model paling dasar dari pemetaan penyakit. Model ini sering digunakan dalam studi epidemiologi untuk mengidentifikasi lokasi dengan tingkat risiko tinggi relative terhadap lokasi yang lainnya. Perbedaan SMR dengan Raw Rate adalah pada pembagi dari angka kasus. Pada SMR pembagi dari angka kasus dalam menghitung risiko adalah nilai harapan angka kasus pada satu lokasi bukan nilai populasi langsung pada lokasi tersebut. Misalkan angka kasus pada lokasi ke- i dinyatakan dengan y_i dan angka harapan kasus pada lokasi yang sama dinyatakan dengan $e_i (i = 1, 2, 3, \dots, N)$, SMR didefinisikan (Clayton and Kaldor, 1987)

$$SMR_i = \frac{y_i}{e_i},$$

dengan e_i didefinisikan sebagai:

$$e_i = N_i \times \frac{\sum_{i=1}^n y_i}{\sum_{i=1}^n N_i},$$

dengan N_i menyatakan ukuran populasi berisiko pada lokasi ke- i . Penaksir risiko relative SMR memiliki beberapa kelemahan 1) penaksir ini tidak memasukkan informasi ketergantungan spasial, 2) memiliki sensitifitas yang tinggi terhadap perbedaan ukuran populasi, yang berakibat pada ketidakreliabelan sebagai penaksir risiko relative dan 3) tidak tepat digunakan untuk kasus-kasus dengan angka kejadian yang kecil. Terkait dengan permasalahan yang terakhir, metode ini dikoreksi menggunakan pendekatan Empirical bayes (Lawson, 2013; Anselin, 2018; Jaya dkk, 2017; Pringle, 1996; Meza, 2003).

Empirical Bayes: Metode ini merupakan pengembangan dari metode SMR di atas untuk mengatasi permasalahan *small area* atau *small number*. Metode ini menggunakan teknik Bayesian.

Inti dari metode ini adalah menari risiko yang tinggi dan rendah ke nilai rata-rata nya sehingga ada pemulusan pada risiko relative. Hal ini didasarkan pada pemikiran bahwa untuk lokasi dengan ukuran populasi yang kecil cenderung memiliki nilai risiko relative yang tinggi sedangkan lokasi dengan populasi yang besar cenderung memiliki risiko relative yang rendah. Sehingga nilai risiko relative ini perlu mendapat pemulusan.

Model yang paling umum digunakan dalam Empirical Bayes adalah Poisson-Gamma model (Java dkk 2017). Misalkan $y_i \sim \text{Poisson}(e_i \theta_i)$ dengan θ_i menyatakan risiko relative pada lokasi ke- i . Pada pendekatan Bayesian, parameter risiko relative θ_i diasumsikan memiliki distribusi peluang yang dikenal dengan distribusi "*prior*". Distribusi prior yang digunakan jika datanya mengikuti distribusi Poisson adalah distribusi Gamma. Hal ini dikarenakan Gamma merupakan conjugate prior untuk distribusi Poisson. Sehingga dalam pendekatan Empirical Bayes, merupakan penggabungan antara distribusi Poisson dengan distribusi Gamma, dengan $\theta_i \sim \text{Gamma}(\alpha, \beta)$ dimana parameter α dikenal dengan *shape* dan β adalah *rate* parameter. Umumnya parameter α dan β ditentukan sama dengan 1. Formulasi untuk empirical bayes dalam menaksir risiko relative adalah (Anselin, Lozano, & Koschinsky, 2006):

$$\hat{\theta}_i = \frac{y_i + \alpha}{N_i + \beta}; i = 1, \dots, n$$

dengan $\hat{\theta}_i$ adalah penaksir risiko relative menggunakan empirical Bayes. Walaupun model ini mampu mengatasi masalah *small area* namun model ini juga memiliki kelemahan dalam hal presisi taksiran jika terdapat ketergantungan spasial dalam data. Untuk mengecek ketergantungan spasial dalam data

secara global dapat menggunakan Moran's Index dan secara local dapat menggunakan Local Moran's Index (LISA)(Anselin, 1988).

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{S_0 \sum_{i=1}^n (y_i - \bar{y})^2}$$

dengan \bar{y} menyatakan rata-rata angka kasus dan $S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}$. Nilai Moran's I berkisar antara -1 sampai dengan 1. Nilai Moran's I yang mendekati 1 mengindikasikan adanya autokorelasi spasial positif yang kuat dan jika nilai mendekati -1 maka mengindikasikan adanya autokorelasi spasial negative yang kuat. Sedangkan jika mendekati nol mengindikasikan tidak adanya autokorelasi spasial atau pola data bersifat random.

LISA

Untuk local indikator dirumuskan sebagai berikut:

$$I_i = \frac{(y_i - \bar{y}) \sum_{j=1}^n w_{ij} (y_j - \bar{y})}{S^2}$$

Dengan $S^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}$ dengan n adalah banyaknya lokasi.

Nilai LISA tidak dijamin dalam interval -1 dan 1. Nilai yang positif semakin besar menunjukkan adanya local autokorelasi positif yang semakin kuat.

Spatial Rate: merupakan pengembangan dari raw rate dengan mengakomodasi ketergantungan spasial yang dinyatakan dalam bobot spasial (W). GeoDa menyediakan berbagai alternative bobot spasial dari *contiguity based* dan *distance based*. Untuk menggunakan model ini maka terlebih dahulu perlu dilakukan pembuatan matrix bobot spasial. Melalui menu *Weight Manager*: Spatial rate diformulasikan(Anselin, Lozano, & Koschinsky, 2006):

$$SMR_i^W = \frac{\sum_{j=1}^n w_{ij} y_j}{\sum_{j=1}^n w_{ij} N_j}$$

dengan SMR_i^W merupakan ukuran spatial rate dan w_{ij} menyatakan elemen dari matrix bobot spasial.

Spatial Empirical Bayes: merupakan pengembangan

dari metode Empirical bayes dengan memasukkan informasi spasial.

$$\hat{\theta}_i = \frac{\sum_{j=1}^n w_{ij} y_j + \alpha}{\sum_{j=1}^n w_{ij} N_j + \beta}; i = 1, \dots, n$$

Berdasarkan semua model di atas, nilai resiko relative yang lebih besar dari 2 megindikasikan suatu lokasi memiliki resiko yang tinggi (Anselin, Lozano, & Koschinsky, 2006)

HASIL DAN PEMBAHASAN

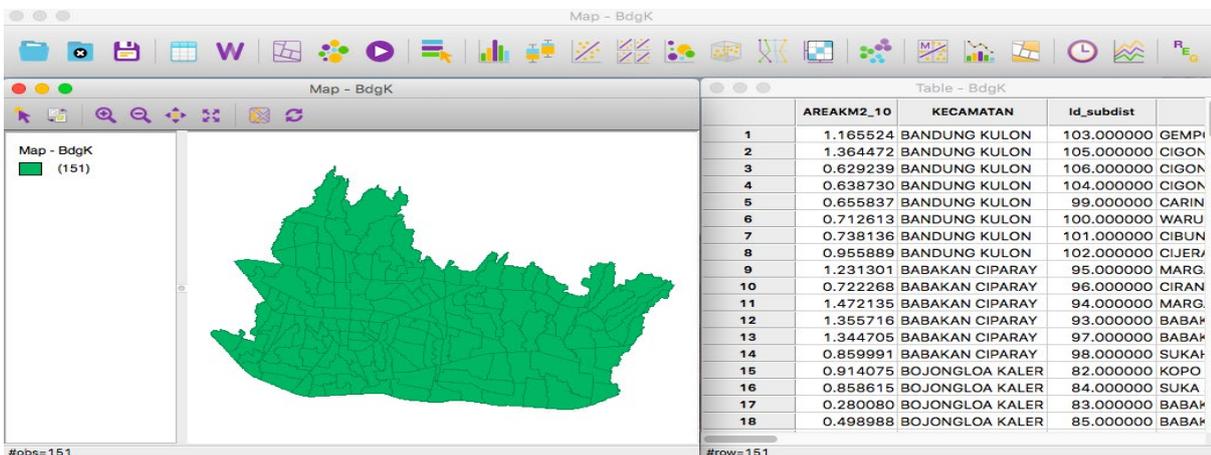
Penggunaan software GeoDa sama dengan software lainnya memerlukan manajemen data. Untuk menggunakan software GeoDa sebainya memiliki data dalam shapefile. Shapefile merupakan format data yang digunakan untuk menyimpan data spasial khususnya peta digital nontopologis berbasis vektor. Format ini memungkinkan menyimpan peta digital berupa bidang (polygon), garis (lines) ataupun titik (point) (Gohil, 2015). Untuk mendapatkan shapefile peta digital khususnya wilayah Indonesia dapat di download melalui website <http://www.info-geospasial.com/2015/10/data-shp-seluruh-indonesia.html>.

Pada artikel ini akan dijelaskan tahapan pemodelan dan pemetaan penyakit demam berdarah di Kota Bandung untuk periode 2016. Penyakit demam berdarah merupakan Penyakit dengan angka kasus yang relatif paling tinggi dibandingkan Penyakit lainnya (Nurulliah, 2016).

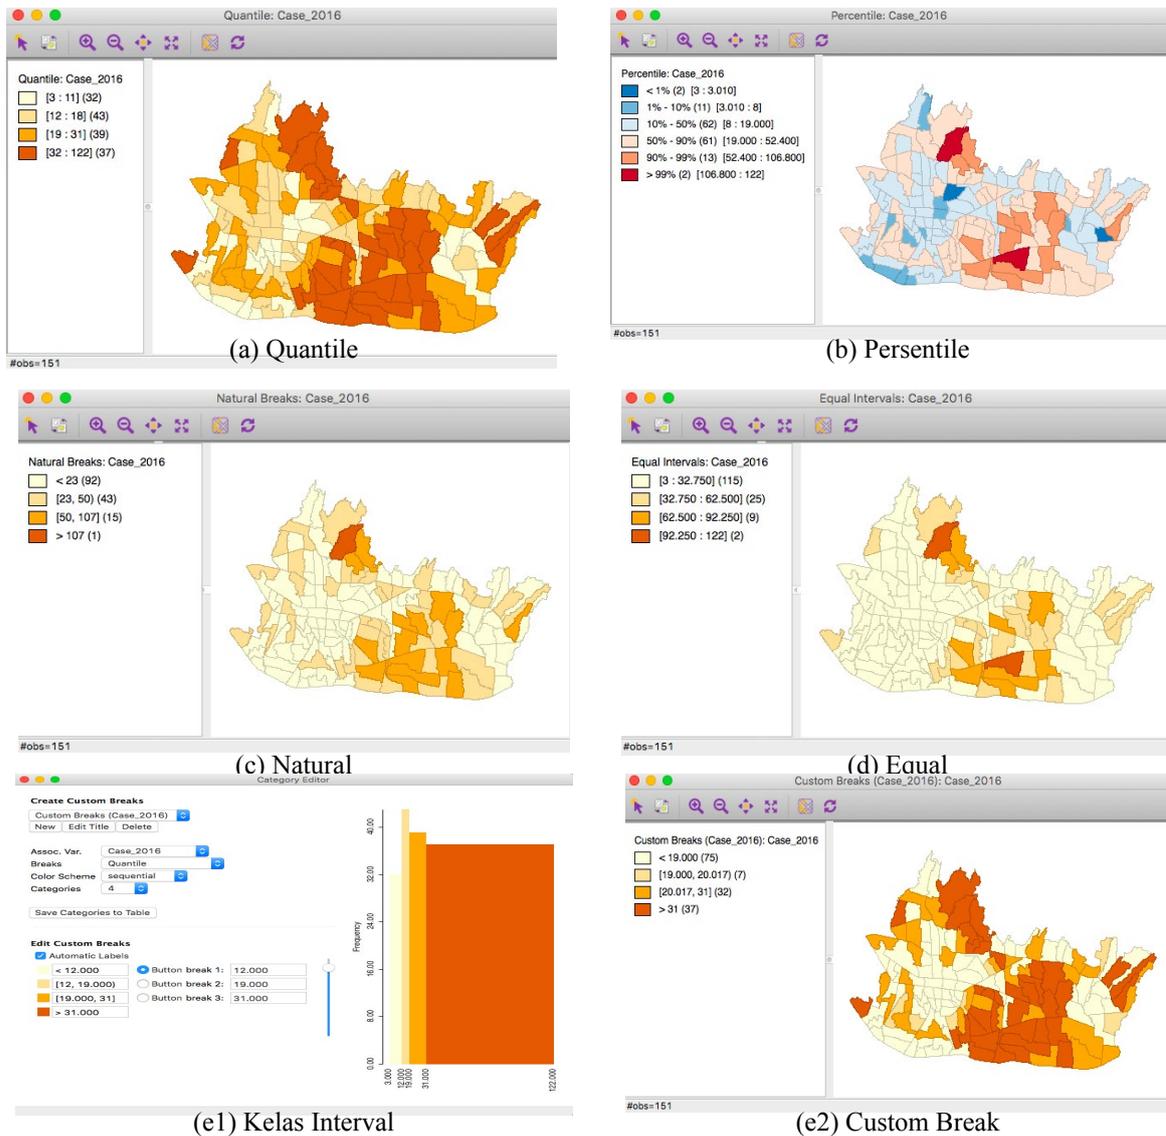
Kota Bandung terdiri dari 151 Kelurahan dengan total penduduk pada Tahun 2016 adalah 2.434.700 dengan angka kasus mencapai 3.830 dengan Incidence Rate (IR) = 158 kasus/100.0000 penduduk.

Pemetaan Angka Kasus dengan GeoDa

GeoDa memfasilitas pemetaan selain pemodelan. Input data untuk GeoDa dapat dilakukan dengan importing data dari program excel. File data harus disimpan dalam format .xls dan disertai *id* data yang sesuai dengan data pada shapefile.



Gambar 1. Tampilan Software GeoDA



Gambar 2. Berbagai jenis peta berdasarkan kelas interval

Pemetaan angka kasus dapat dilakukan dengan beberapa kategori kelas interval: (1) Quantile, (2) Persentile, (3) Natural Breaks Map, (4) Equal Interval Maps dan (5) Custom Breaks. Untuk dapat menyajikan kelima jenis map ini dapat dilakukan melalui menu Map pada GeoDA

Gambar 2(1-5) menyajikan berbagai pilihan peta menurut kelas interval disediakan dalam GeoDa. Untuk pemetaan angka kasus demam berdarah menggunakan custome breaks terlebih dahulu harus menentukan kelas interval yang diinginkan sesuai dengan rujukan yang dimiliki. Dalam GeoDa menunya tersedia pada menu “Create New Custom”. Jenis peta yang akan dipilih harus didasarkan pada rujukan yang jelas karena setiap pilihan jenis peta akan mempresentasikan visualisasi yang berbeda dan setiap peta memberikan kesimpulan yang berbeda terhadap lokasi angka kasus tinggi ataupun rendah.

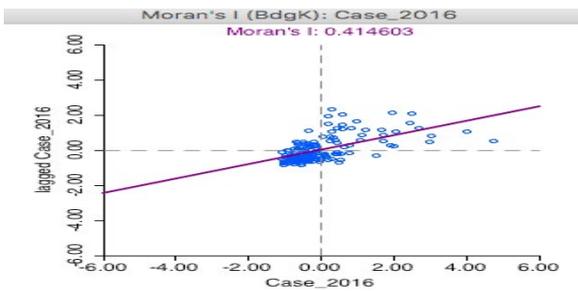
Nilai tinggi umumnya digambarkan dengan warna yang lebih gelap. Terlihat secara umum daerah Bandung Utara dan juga selatan mencatatkan angka kasus yang tinggi. Sedangkan Bandung bagian barat relative rendah kecuali kecamatan Gempol Sari.

Jika diperhatikan dari kelima peta di atas, dapat dilihat hasil visualisasinya berbeda sehingga harus dicermati dengan baik. Namun, peta ini tidak dapat dijadikan rujukan untuk mengetahui resiko tinggi ataupun rendah suatu lokasi karena untuk resiko tinggi rendah suatu lokasi harus memperhatikan atribut spasial pada suatu lokasi seperti ukuran populasi berisiko dan juga rentang usia dari populasi tersebut.

Spatial Autocorrelation

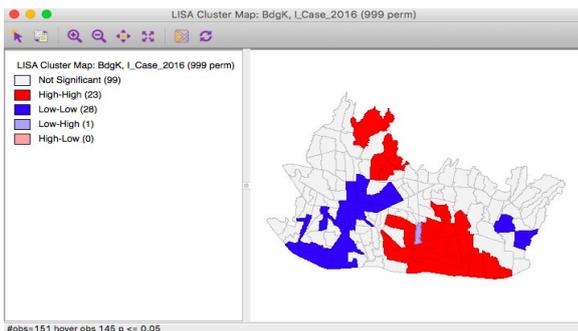
Tahap analisis selanjutnya yang harus menjadi perhatian adalah identifikasi autokorelasi spasial. Ini akan membantu menentukan model risiko mana yang lebih tepat untuk digunakan pada data yang dimiliki. Global autokorelasi bisa dilihat dari Moran’s Index dan local autokorelasi dapat dilihat dari LISA. Global autokorelasi menyatakan autokorelasi untuk keseluruhan lokasi sedangkan local untuk masing-masing lokasi.

Hasil perhitungan Global autokorelasi memberikan nilai 0.415 menunjukkan adanya autokorasi yang kuat (Gambar 3).



Gambar 3. Global autokoralsasi

Selanjutnya untuk Local autokorelation yang paling dipentingkan dari ukuran ini adalah nilai p.value nya bukan nilai Local-moran sendiri untuk tujuan mengetahui lokasi-lokasi mana yang memiliki kemiripan nilai resiko.



Gambar 4. p.value Local Moran's

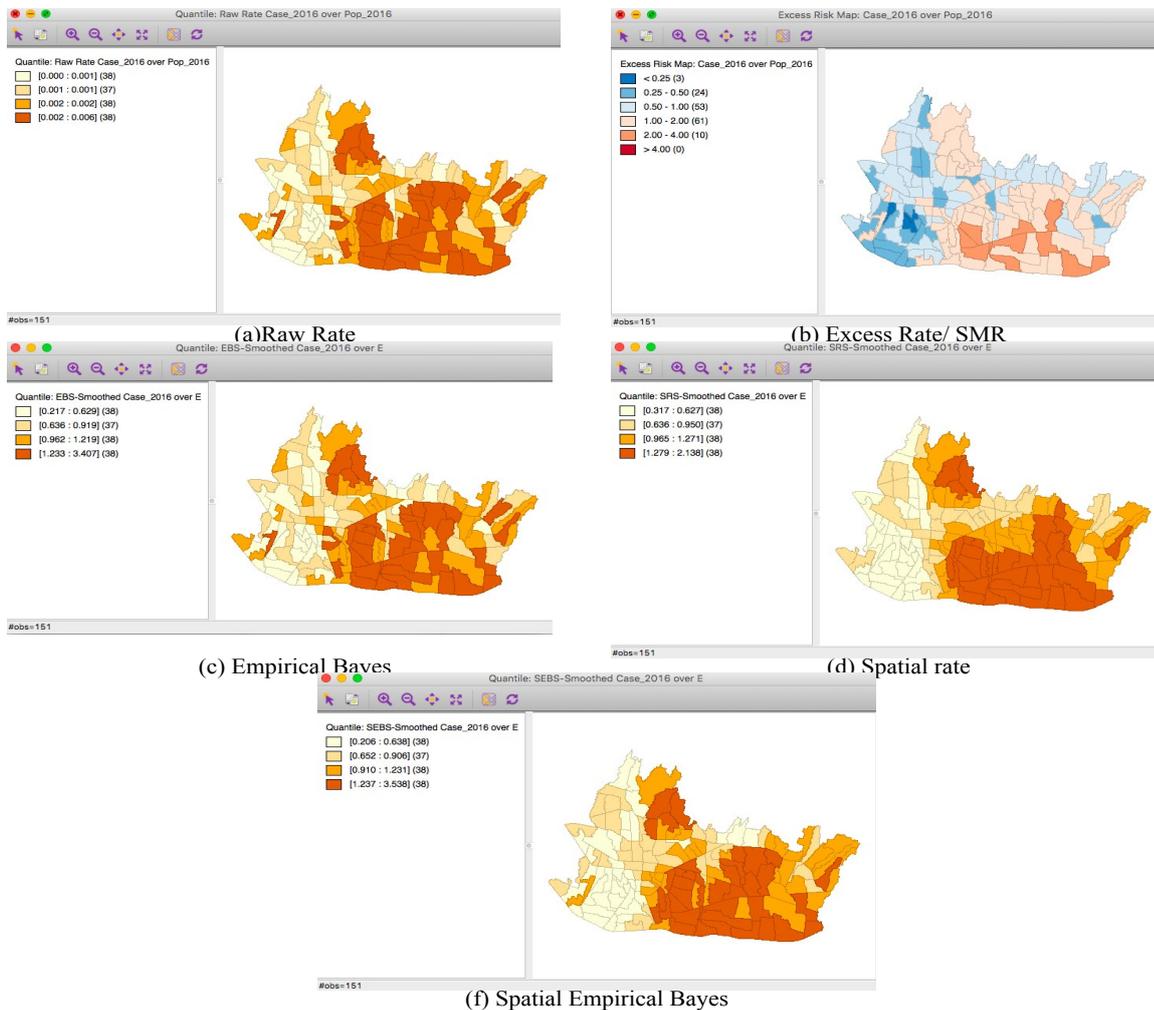
Terlihat ada gambar ada tiga kelompok yaitu yang tidak signifikan (abu-abu), signifikan tinggi-tinggi (merah), dan signifikan rendah-rendah (biru). Dalam hal ini yang menjadi fokus perhatian adalah warna merah.

Informasi ini juga akan dimanfaatkan untuk mendukung penentuan model yang akan digunakan untuk menaksir resiko relatif.

Pemodelan dan Pemetaan Resiko Relative

Berbagai peta pemetaan penyakit yang menunjukkan distribusi atau pola penyebaran penyakit demam berdarah dengan lima model berbeda disajikan dalam Gambar 5.

Gambar 5(1-5) menunjukkan peta risiko penyakit demam berdarah untuk berbagai model. Sama hal nya dengan pemetaan angka kasus, peta yang diperoleh memberikan visualisasi yang berbeda beda dan memungkinkan adanya kekeliruan dalam pengambilan keputusan. Sehingga pemahaman tentang dasar pemilihan model yang mana yang harus digunakan menjadi keharusan untuk menghindari kesalahan. Dalam hal ini mengacu pada hasil yang diperoleh pada Moran's I maka sebaiknya model yang digunakan dalam mengidentifikasi lokasi tinggi rendah kasus demam berdarah adalah peta yang memerhatikan ketergantungan spasial.



Gambar 5. Pemetaan resiko berdasarkan model (1-5)

SIMPULAN

GeoDa merupakan free software yang sangat membantu dalam pemodelan dan pemetaan Penyakit. Namun, keterbatasan pemahaman tentang alat analisis dapat menyebabkan praktisi melakukan perkeliruan dalam analisis. GeoDa menyajikan berbagai alat untuk pemetaan data geografi sehingga praktisi harus memiliki pemahaman yang baik pada statistik dan aspek praktis untuk mengoptimalkan pemanfaatan software GeoDa ini.

Pada akhirnya software hanyalah sebuah alat yang mempermudah praktisi dalam melakukan pemodelan namun kemampuan dalam mengoperasikan, memiliki pemahaman yang baik terhadap metode dibalik setiap menu akan mengoptimalkan peran dari GeoDa dalam membantuk praktisi menganalisis data penyakit khususnya Penyakit.

Seperti kasus demam berdarah, melalui pemodelan dan pemetaan resiko relatif dari penyakit ini, praktisi dapat melihat gambaran secara lebih jelas lokasi-lokasi yang memiliki resiko tinggi demam berdarah sehingga pemerintah daerah kota Bandung melalui dinas kesehatan dapat menentukan strategi yang tepat pada lokasi yang tepat.

UCAPAN TERIMAKASIH

Kami mengucapkan terimakasih kepada Rektor Universitas Padjadjaran, melalui skema Hibah Internal Unpad (HIU)-RFU (no. Kontrak: 1732 d/UN6.RKT/LT/2018), pengabdian kepada masyarakat Dinas Kesehatan Kota Bandung dapat direalisasikan. Terimakasih juga kami ucapkan kepada Dinas Kesehatan Kota Bandung atas data-data yang sangat membantu penulisan karya pengabdian masyarakat ini.

DAFTAR PUSTAKA

- Anderson, C., & Ryan, L. M. (2017). A Comparison of Spatio-Temporal Disease Mapping Approaches Including an Application to Ischaemic Heart Disease in New South Wales, Australia. *International Journal of Environmental Research and Public Health*, 14(146), 1-16. doi:10.3390/ijerph14020146
- Anselin, L. (1988). *Spatial Econometrics: Methods and Models*. Netherlands: Springer.
- Anselin, L. (2003). *GeoDaTM 0.9 User's Guide*. Urbana-Champaign: Spatial Analysis Laboratory.
- Anselin, L. (2018). *GeoDa*. Retrieved from Maps for Rates or Proportions: https://geodacenter.github.io/workbook/3b_rates/lab3b.html
- Anselin, L., Lozano, L., & Koschinsky, J. (2006). *Rate transformations and smoothing*. Urbana-Champaign: Spatial Analysis Laboratory Department of Geography University of Illinois.
- Anselin, L., Syabri, I., & Kho, Y. (2006). *GeoDa: An Introduction to Spatial Data Analysis*. *Geographical Analysis*, 38, 5-22.
- Arab, A. (2015). Spatial and Spatio-Temporal Models for Modeling Epidemiological Data with Excess Zeros. *Int. J. Environ. Res. Public Health*, 12(9), 10536-10548.
- Clayton, D., & Kaldor, J. (1987). Empirical Bayes Estimates of Age-Standardized Relative Risks for Use in Disease Mapping. *Biometrics*, 671-681.
- Gohil, A. (2015). *R Data Visualization Cookbook*. Mumbai: PACKT Publishing.
- Jaya, I. G., Folmer, H., Ruchjana, B. N., Kristiani, F., & Andriyana, Y. (2017). Modeling of Infectious Diseases: A Core Research Topic for the Next Hundred Years. In R. Jackson, & P. Schaeffer, *Regional Research Frontiers-Vol 2* (pp. 239-255). United State: Springer International Publishing.
- Jaya, I. G., Ruchjana, B. N., Abdulah, A. S., & Hermawan, E. (2016). Bayesian Spatial Modeling and Mapping of Dengue Fever: A Case Study of Dengue Fever in the City of Bandung, Indonesia. *International Journal of Applied Mathematics and Statistics*, 54(3), 94-103.
- Lawson, A. (2013). *Bayesian Disease Mapping, Hierarchical Modelling in Spatial Epidemiology* (2nd ed.). CRC Press Taylor and Francis Group.
- Lawson, A. B. (2006). *Statistical Methods Methods in Spatial Epidemiology*. England: John Wiley & Sons.
- Lee, D., & Lawson, A. (2015). Cluster detection and risk estimation for spatio-temporal health data. *Annals of the Institute*, 43(1), 1-59.
- Liu, Y., Watson, S. C., Gettings, J. R., Lund, R. B., Nordone, S. K., Yabsley, M. J., & McMahan, C. S. (2017). A Bayesian spatio-temporal model for forecasting Anaplasma species seroprevalence in domestic dogs within the contiguous United States. *PLOS ONE*, 1-18.
- Lloyd, C. (2010). *Spatial data analysis*. New York: OXFORD University Press.
- Meza, J. (2003). Empirical Bayes estimation smoothing of relative risks in disease mapping. *Journal of Statistical Planning and Inference*, 112, 43-62.

Nurulliah, N. (2016, November 4). Pikiran Rakyat. Retrieved from Kasus Demam Berdarah Terbanyak Terjadi di Kota Bandung, Waspadalah!: <http://www.pikiran-rakyat.com/bandung-raya/2016/11/04/kasus-demam-berdarah-terbanyak-terjadi-di-kota-bandung-waspadalah-383883>

Pringle, D. (1996). Mapping Disease Risk Estimates Based on Small Numbers: An Assessment of Empirical Bayes Techniques. *The Economic and Social Review*, 27(4), 341-363.

WHO. (2009). *Who Guide to Identifying The Economic Consequences of Disease and Injury*. Geneva: WHO.