

PEMODELAN CITRA MALAM UNTUK ESTIMASI KEMISKINAN DESA







PEMODELAN CITRA MALAM UNTUK ESTIMASI KEMISKINAN DESA

No. ISBN : 978-602-438-520-0

No. Publikasi : 07300.2215

No. Katalog : 3205029

Ukuran Buku : 17,6 cm x 25 cm

Jumlah Halaman : viii+ 72 halaman

Naskah : Direktorat Analisis dan Pengembangan Statistik

Gambar Kulit : Direktorat Analisis dan Pengembangan Statistik

Sumber Ilustrasi : www.freepik.com; www.pixabay.com

Diterbitkan oleh : Badan Pusat Statistik

Dilarang mengumumkan, mengomunikasikan, dan/atau menggandakan sebagian atau seluruh isi buku ini untuk tujuan komersial tanpa izin tertulis dari Badan Pusat Statistik



Kata Pengantar

Puji syukur kehadiran Allah SWT yang telah memberikan rahmat dan hidayah-Nya atas selesainya publikasi Pemodelan Citra Malam untuk Estimasi Kemiskinan Desa yang merupakan salah satu hasil kajian pengembangan Big Data yang dilakukan oleh Fungsi Pengembangan Model Statistik, Direktorat Analisis dan Pengembangan Statistik pada tahun 2022. Tujuan publikasi ini adalah mengkaji kemungkinan dilakukannya estimasi kemiskinan pada level yang lebih granular yaitu pada level desa dengan menggunakan sumber big data dari citra satelit dan pendekatan pemodelan dengan machine learning.

Pada Bab pertama dibahas secara singkat latar belakang dan beberapa studi terdahulu terkait estimasi kemiskinan menggunakan citra satelit. Bab kedua memaparkan secara detail mengenai citra satelit, data shapefile, dan data hasil pendataan Potensi Desa 2018 (PODES 2018) yang digunakan dalam pemodelan kemiskinan. Pada Bab ketiga dipaparkan metodologi pemodelan estimasi kemiskinan dengan citra satelit menggunakan machine learning. Bab keempat memaparkan secara rinci hasil pemodelan kemiskinan di seluruh provinsi di Indonesia dan pembahasan tentang kemungkinannya untuk diterapkan pada kasus Indonesia. Bab kelima memberikan gambaran keterkaitan hasil estimasi kemiskinan pada level desa dengan karakteristik wilayah menurut data PODES 2018.

Kajian ini diharapkan dapat mendukung statistik resmi yang dihasilkan oleh BPS khususnya dalam menentukan tingkat kemiskinan pada level yang lebih kecil. Ucapan terima kasih dan apresiasi kami sampaikan kepada seluruh pihak yang telah membantu dan memberi masukan dalam penyusunan publikasi ini. Semoga publikasi ini dapat memberikan informasi yang bermanfaat bagi para pengguna dan pihak lain yang berkepentingan.

Jakarta, Agustus 2022



Moh. Edy Mahmud



Daftar

BAB I

2 - Latar Belakang

3 - Data Geospasial

5 - Pemetaan Kemiskinan Citra
Satelit

5 - Tujuan

6 - Skema Penulisan

6 - Ucapan Terimakasih

BAB II

8 - Podes 2018

12 - *Night Time Light*

BAB III

16 - Desain Pemodelan

17 - Ekstraksi Fitur

19 - Transformasi Data

21 - Normalisasi Data

21 - Model Prediksi

24 - Evaluasi Kebaikan
Model



isi

BAB IV

28 - Analisis Model

35 - Hasil Estimasi
Kemiskinan Beberapa
Provinsi

41 - Pembahasan

BAB V

44 - Gambaran Umum Hasil
Estimasi Kemiskinan dan
Night Time Light (NTL)

46 - Keterkaitan Kemiskinan
dengan karakteristik Wilayah
Berdasarkan Data PODES
2018



PENGARAH

Muchammad Romzi

PENANGGUNG JAWAB

Setia Pramana

EDITOR

Direktorat Analisis dan Pengembangan Statistik

Usman Bustaman

Dhiar Niken Larasati

Setia Pramana

Politeknik Statistik - STIS

Arie Wahyu Wijayanto

Nucke Widowati Projo

Rindang Bangun Prasetyo

LAYOUT

Maulana Faris

COVER DESIGN

I Nyoman Setiawan

PENULIS

Dhiar Niken Larasati

Khairunnisah

Maulana Faris

Dewi Lestari Amaliah

Nensi Fitria Deli

Ana Lailatul Fitriyani

Dede Yoga Paramartha

Satria Bagus Panuntun

Maria Audrey Widyawati

PENGOLAH DATA

Kasiful Aprianto

Satria Bagus Panuntun







PENDAHULUAN

1.1. Latar Belakang

Komitmen masyarakat internasional untuk mengentaskan kemiskinan tanpa meninggalkan siapa pun (*no one left behind*), terlihat dengan dijadikannya *no poverty* menjadi tujuan pertama dalam Agenda 2030, *Sustainable Development Goals* (SDGs). Pemerintah Indonesia memasuki tahun 2022 mencanangkan target ambisius untuk penanggulangan kemiskinan yaitu ke tingkat 8,5-9,0 persen. Tingkat kemiskinan di Bulan Maret 2022 tercatat mencapai 9,54 persen atau sebanyak 26,16 juta orang.

Salah satu kendala dalam proses pengentasan kemiskinan adalah ketersediaan data kemiskinan yang lebih granular. Diperlukan data dan pemetaan yg lebih granular atau lebih detail, dari sisi cakupan wilayah (misalnya desa) dan juga waktu (bulanan, atau triwulanan). Namun untuk mendapatkan hasil estimasi dalam lingkup lebih kecil, diperlukan jumlah sampel yang sangat besar yang akan berpengaruh terhadap biaya dan waktu survei.

Badan Pusat Statistik saat ini melakukan penghitungan kemiskinan berdasarkan hasil Survei sosial ekonomi nasional (Susenas) yang dilakukan dua kali dalam setahun. Pada bulan Maret susenas dilaksanakan pada 320.000 sampel rumah tangga seluruh Indonesia, dan dapat menghasilkan estimasi pada level provinsi dan kabupaten kota. Sedangkan untuk Bulan September besar sampel hanya 75.000 rumah tangga sehingga hanya didapat tingkat kemiskinan pada level provinsi.

Keterbatasan kegiatan statistik konvensional (seperti surveil dan sensus) telah membuat PBB mengkampanyekan revolusi data dengan melakukan pengumpulan



data pada frekuensi yang lebih tinggi dan lebih detail. Dengan semakin berkembangnya teknologi digital saat ini yang menghasilkan berbagai jenis alternatif data yang dapat digunakan dalam penyediaan statistik resmi, termasuk data kemiskinan. Berbagai sumber data *alternative* itu antara lain data administrative, Transaksi, Sensor, dan konten digital (berita, sosial media, dll).

1.2. Data Geospasial

Data Geospasial dan Observasi bumi (*Earth Observation*, EO) merupakan salah satu sumber data *alternative* yang saat ini sedang dikembangkan untuk mengungkap fenomena dan mengukur berbagai aktifitas ekonomi dan sosial masyarakat. Salah satu teknologi dalam bidang EO adalah citra satelit (*satellite imagery*) yang merupakan gambar hasil rekaman lensa kamera atau sensor yang dipasang pada satelit di luar angkasa dengan ketinggian lebih dari 400 km dari permukaan bumi. Citra satelit diperoleh dari proses penginderaan jauh atau *remote sensing*. Sensor dari penginderaan jauh merekam energi yang dipantulkan atau dipancarkan oleh objek yang berada pada permukaan bumi (BPS, 2022).

Sistem *remote sensing*, terutama yang dipasang pada satelit, dapat menangkap pandangan permukaan bumi secara berulang dan konsisten, sehingga dapat digunakan untuk memantau perubahan permukaan bumi jangka pendek maupun jangka panjang sebagai dampak proses alam atau aktivitas manusia (Schowengerdt, 2006). Penginderaan jauh dapat digunakan sebagai sumber data dasar karena hasil yang diukur dari sifat fisis benda-benda jauh dengan menggunakan energi yang dipantulkan dan dipancarkan, terlepas dari di mana mereka direkam merupakan data.

Data Earth Observation (EO) dapat dimanfaatkan untuk berbagai tujuan yang secara umum dibagi menjadi 4 kelompok, yaitu (1) pemanfaatan untuk sumber daya alam

darat, (2) pemanfaatan untuk sumberdaya alam pesisir dan laut, (3) pemanfaatan untuk lingkungan dan kebencanaan, dan (4) pemanfaatan untuk kepentingan strategis lainnya (Khomarudin, dkk., 2022). Kelompok ke empat mencakup bidang kesehatan, pertanian, ekonomi, sosial dan bidang lainnya.

Data EO dapat digunakan untuk meningkatkan pemahaman, pencegahan, dan pengendalian penyakit yang ditularkan melalui vektor misalnya malaria (Gebreslasie, 2015). Selanjutnya analisis spasial yang dikembangkan dapat digunakan untuk mengidentifikasi lokasi dan risiko penyakit dan serta penanggulangannya. Dalam hal lingkungan, citra satelit dapat digunakan untuk memperkirakan kerusakan lingkungan secara umum (Kurniawan dkk., 2022) maupun dikarenakan kebakaran hutan (Afira dan Wijayanto, 2022).

Untuk bidang pertanian, berbagai hasil pengolahan data satelit seperti tutupan lahan, indeks vegetasi (NDVI & EVI), suhu permukaan tanah, dan curah hujan dapat digunakan untuk mendukung parameter lingkungan seperti dampak kegiatan pertanian pada skala lokal dan regional, serta analisis estimasi panen, kualitas tanah dan ketersediaan air.

Data citra satelit dapat mengekstrak berbagai jenis infrastruktur misalnya jaringan jalan; rencana pembangunan infrastruktur, pemetaan topografi sehingga berpeluang untuk membantu survei demografi dan kesehatan (*Demographic and Health Surveys*) dengan memantau kondisi bangunan perkotaan, perkembangan fasilitas Pendidikan, dan kesehatan, seperti akses listrik dan air minum. Kemudian, data EO berupa citra lampu waktu malam dapat memantau secara sistematis sebaran akses listrik, memetakan aktivitas manusia, serta untuk memantau potensi penggunaan daya listrik.

Citra satelit dapat digunakan untuk mengidentifikasi tingkat kemiskinan dari suatu wilayah melalui analisis cahaya malam, pemetaan karakteristik bangunan, parameter fisik berupa jaringan jalan (akses) dan bentuk dan material bangunan (Montana et al., 2016). Dengan citra siang, kita dapat mengidentifikasi *Generic Slum Ontology* (GSO) dan memperkirakan tingkat pemukiman kumuh (kepadatan dan bentuk) dan lingkungan kumuh (karakteristik lokasi dan lingkungan).

Dalam melakukan analisis dari citra satelit dapat dilakukan dengan tiga pendekatan, (1) analisis turunan (*proxy*); (2) *Object-Based Image* (OBIA or GEOBIA); dan (3) *Machine learning techniques*, misalnya *Random Forest*, *Neural networks*, *Support Vector Machines* (Agustan, 2021). Citra satelit dalam analisisnya perlu dikombinasikan dengan berbagai data lainnya seperti hasil survei dan sensus, data administrative, serta sumber data lainnya dengan menggunakan berbagai teknik *Deep Learning* dan Kecerdasan Artifisial untuk menghasilkan berbagai data, informasi dan statistik yang diharapkan (Jean dkk, 2016).

1.3. Pemetaan Kemiskinan dengan Citra Satelit

Salah satu potensi penggunaan citra satelit adalah untuk mengestimasi tingkat kemiskinan dari suatu wilayah berdasar baik citra siang maupun citra malam. Jean dkk, (2016) membangun model berbasis citra satelit malam dan siang hari dengan ridge regression dan Resnet34 untuk mengestimasi kemiskinan di negara-negara Afrika. Martinez, dkk (2020) melakukan proses yang namun dengan implementasi di negara Filipina dan Thailand. Xu. Dkk (2021) dan Puttanapong dkk (2022) menggunakan berbagai sumber citra satelit dan dengan Teknik deep learning untuk membangun model estimasi untuk Tiongkok dan Thailand.

Untuk implementasi di Indonesia, Ngestrini.,(2019) menggunakan pendekatan Convolutional *Neural network* (CNN) model dengan citra satelit siang (*daytime satellite imagery*) untuk mengukur tingkat kemiskinan pada level *grid* 5 km. Selanjutnya Aprianto, 2022, dan Khairunnisah 2022, melakukan pendekatan yang sama untuk propinsi Banten dan Yogyakarta untuk level yang lebih kecil, yakni *grid* 1km. Putri, dkk., (2022a), dan dan Putri, dkk., (2022b) menggunakan data dari berbagai sumber untuk menghitung spatial relative poverty index untuk Propinsi Jawa Timur.

Citra Satelit dapat digabungkan dengan berbagai sumber data lain untuk meningkatkan kualitas estimasi dan pemetaan kemiskinan. Sumber data yang dapat digunakan seperti *google connectivity* indeks yang dilakukan oleh Chi dkk 2022, dan *Facebook Advertising Data* yang diimplementasikan oleh Ledesma dkk (2020). Selain itu *Point of Interest* (POI) yang didapatkan dari *Open Street Map*, maupun *Google Map* dapat juga digunakan untuk melengkapi estimasi, seperti yang dilakukan oleh untuk Tingzon 2019, Shie dkk 2020, dan Putri, dkk., (2022b).

Berbagai sumber Citra satelit dengan berbagai resolusi serta proses pengambilan data dan Langkah-langkah *Preprocessing* yang perlu dilakukan sebelum data tersebut dapat dianalisis telah dijelaskan secara detail pada buku Teknik Pengumpulan Data dan *Preprocessing* Citra Satelit yang dihasilkan oleh Direktorat Analisis dan Pengembangan Model, Badan Pusat Statistik (BPS, 2022).

1.4. Tujuan

Buku ini bertujuan untuk melakukan estimasi, analisis dan pemetaan kemiskinan di Indonesia pada level desa dengan menggunakan data citra satelit dengan beberap algoritma *machine learning* terkini, seperti *multilayer perceptron* (MLP) dan *XGBoost*. Selain itu analisis mendalam terkait hasil estimasi yang telah dilakukan dengan berbagai statistic resmi (*official statistics*) yang ada, seperti Indeks Pembangunan Manusia (IPM), dan pertumbuhan ekonomi (PDRB).

Selanjutnya, buku ini diharapkan dapat dijadikan rujukan bagi setiap pembaca, baik pegawai BPS, peneliti maupun pembaca lainnya untuk meningkatkan pengetahuan terkait analisis citra satelit untuk estimasi dan pemetaan kemiskinan.

Secara rinci buku ini bertujuan untuk:

1. Meningkatkan kemampuan sumber daya manusia (SDM) baik di lingkungan BPS ataupun pembaca lainnya agar dapat melakukan proses analisis data citra satelit untuk pemetaan kemiskinan.
2. Memberikan gambaran penggunaan sumber data alternatif dari berbagai sumber Big Data untuk menghasilkan statistik baik untuk penunjang maupun komplemen data dan statistik resmi yang dihasilkan oleh BPS.
3. Memberikan pemahaman kepada pembaca mengenai proses pengolahan data citra satelit sebagai sumber data pendukung kegiatan statistik untuk mendapatkan data yang lebih granular.

1.5. Skema penulisan

Skema penulisan buku ini adalah sebagai berikut: Bab 2 berisi tentang berbagai data yang digunakan, dari data Potensi Desa, serta data *Night Time Lights* (NTL) yang digunakan untuk permodelan. Bab 3 menjelaskan metode yang digunakan, yang dimulai dengan transformasi data, metode *multilayer perceptron* (MLP) dan *XGBoost* serta pengecekan hasil estimasi yang didapatkan. Bab 4 akan memberikan interpretasi hasil yang didapat dan dilanjutkan dengan Perbandingan hasil estimasi dengan *official statistic* yang ada pada Bab 5.

1.6. Ucapan Terimakasih

Kajian ini dalam prosesnya telah mendapatkan ulasan serta saran dan masukan dari para akademisi dan pakar. Untuk itu ucapan terima kasih ditujukan khususnya kepada Bapak Dr. Ir. Alexander Agung Santoso Gunawan, M.Si., M.Sc., IPM dari Universitas Bina Nusantara atas komentar dan masukan yang sangat berharga dalam penyusunan kajian ini. Selain itu kami juga mengucapkan penghargaan dan terimakasih kepada seluruh tim penyusun, diantaranya: Pusat Riset Penginderaan Jauh - Organisasi Riset Penerbangan dan Antariksa BRIN yang telah membantu penulisan publikasi ini, sekaligus melakukan beberapa kali capacity building di BPS. Politeknik Statistika STIS yang telah melakukan berbagai riset terkait eksplorasi sumber data baru, pengembangan metode dan algoritma terbaru terkait *big data*. Direktorat Sistem Informasi Statistik yang telah mengupayakan tersedianya infrastruktur untuk melakukan proses penyimpanan dan pengolahan *big data*. Direktorat Pengembangan Metodologi Sensus dan Survei yang telah berkontribusi dalam pengembangan data citra satelit untuk pemodelan. Direktorat Analisis dan Pengembangan Statistik yang telah memberikan saran dan masukan terkait hasil analisis big data yang telah dilakukan; serta beberapa *subject matter* lainnya di BPS yang telah memberikan masukan dan dukungan dengan memanfaatkan diseminasi big data yang telah dilakukan.





POTENSI DESA DAN CITRA SATELIT

Satria Bagus Panuntun, Maria Audrey Widyawati

2.1. PODES

Official Statistics yang biasa disebut statistik dasar adalah statistik yang pemanfaatannya ditujukan untuk keperluan yang bersifat luas, baik pemerintahan maupun masyarakat yang memiliki ciri-ciri lintas sektoral, berskala nasional maupun regional, makro dan penyelenggaraanya menjadi tanggung jawab Badan Pusat Statistik (BPS). Menurut UN Statistik dasar menyediakan informasi bidang ekonomi, kesejahteraan rakyat dan bidang-bidang lainnya.

Potensi Desa atau PODES merupakan salah satu data *official statistic* yang menyediakan data potensi desa dan ketersediaan infrastruktur yang berbasis kewilayahan (spasial) dari tingkat nasional, provinsi, kabupaten/kota, kecamatan hingga satuan setingkat desa satu-satunya yang dimiliki BPS yang menekankan pada potensi suatu wilayah. Pendataan Podes sudah dilaksanakan oleh BPS sejak tahun 1980 bersamaan dengan sensus penduduk 1980. Namun, sejak 2008 Podes dilakukan secara independen dari program sensus lainnya. Kegiatan Podes dilaksanakan tiga kali dalam sepuluh tahun yakni : dua tahun sebelum sensus penduduk (tahun berakhir 0), 2 tahun sebelum sensus pertanian (tahun berakhir 3) dan tahun sebelum sensus ekonomi (tahun berakhir 6). Data Podes adalah instrumen yang digunakan untuk mendukung pembangunan desa, sebagaimana diamanatkan oleh Undang-Undang No. 6 Tahun 2014 Tentang Desa.



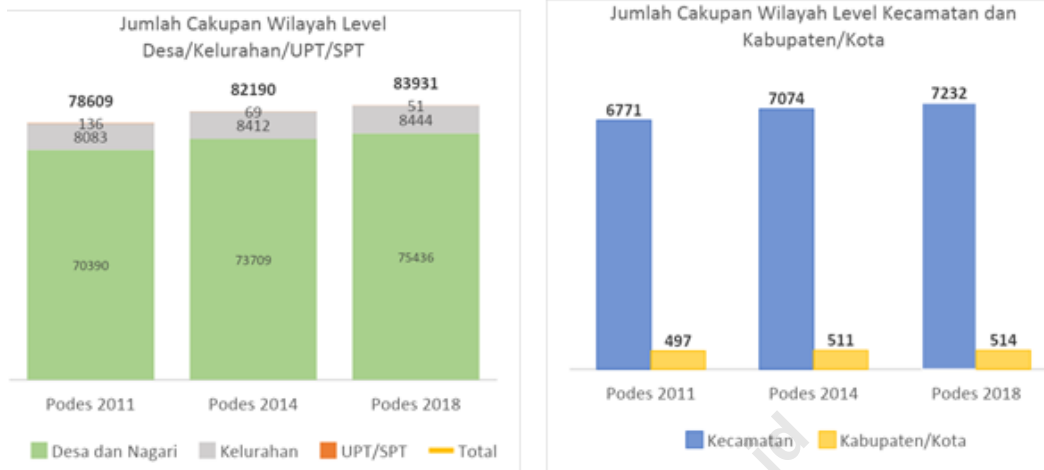
sumber : Pixabay.com

Pendataan Podes 2018 memberikan informasi dasar beberapa variabel dalam SP2020 dan pendukung perencanaan kegiatan SP2020. Pendataan dilaksanakan pada Mei 2018 secara serentak di seluruh wilayah Indonesia. Podes 2018 memiliki beberapa tujuan, diantaranya:

1. Menyediakan data pendukung perencanaan SP2020.
2. Sarana *updating master file desa* (MFD) yang berisikan nama-nama desa dan kode identitas.
3. Menyediakan data potensi desa yang meliputi sosial, ekonomi dan prasarana.
4. Menyediakan data untuk *updating klasifikasi desa*
5. Sumber data pemutakhiran peta wilayah kerja statistik
6. Menyediakan data bagi penyusunan statistik wilayah kecil (*small area estimation*)
7. Menyediakan data bagi penyusunan berbagai analisis
8. Menyediakan data bagi penghitungan indikator-indikator pembangunan desa.

Cakupan wilayah pendataan podes pada level terkecil yaitu desa, kelurahan, nigari, dan satuan pemutakhiran transmigrasi (SPT) atau unit pemutakhiran transmigrasi (UPT) yang masih dibina kementerian terkait di seluruh Indonesia. Podes 2018 dilaksanakan secara sensus terhadap seluruh kabupaten/kota, kecamatan dan wilayah setingkat desa. Hasil dari Podes 2018 telah mencakup sebanyak 83.931 wilayah setingkat desa yang terdiri dari 75.436 desa (desa dan nigari untuk Sulawesi barat), 8.444 kelurahan dan 51 UPT/SPT. wilayah kecamatan sebanyak 7.232 kecamatan dan wilayah kabupaten sebanyak 514





gambar 2.1

Data yang telah dikumpulkan dengan instrumen Podes 2018 menggunakan tiga kuesioner sesuai jenjang kewilayahan yaitu: level desa (PODES2018-DESA), kecamatan (PODES2018-KEC), kabupaten/kota (PODES2018-KAB/KOTA). Data yang dikumpulkan dari ketiga kuesioner ini adalah sebagai berikut:

1. Keterangan Umum Desa Kelurahan
2. Kependudukan dan Ketenagakerjaan
3. Perumahan dan Lingkungan Hidup,
4. Bencana Alam dan Mitigasi Bencana Alam
5. Pendidikan dan Kesehatan
6. Sosial Budaya
7. Olahraga dan Hiburan
8. Angkutan, Komunikasi dan Informasi
9. Penggunaan Lahan
10. Ekonomi
11. Keamanan
12. Otonomi Desa dan Program Pemberdayaan Masyarakat
13. Keterangan aparatur pemerintahan desa/kelurahan
14. Modul


Data yang telah dikumpulkan pada podes 2018 mengacu pada saat situasi pencacahan Mei 2018, kecuali pada beberapa pertanyaan yang telah ditetapkan referensinya. Data Podes juga merupakan data yang dikumpulkan bukan dengan pendekatan rumah tangga dengan metode pencacahan langsung kepada narasumber terkait yang berwenang dan relevan serta penelusuran dokumen yang ada di desa/kelurahan, kecamatan, maupun kabupaten/kota. Lampiran instrumen kuesioner dapat dilihat di lampiran 1.

Pemanfaatandatapodesdapatdigunakanoleh masyarakatluasdanpemerintahan yang membutuhkan sebagai penyusunan berbagai analisis dan kebijakan terkait kewilayahan, dan sebagai penghitungan indikator-indikator pembangunan/kemajuan desa. Beberapa penelitian yang menggunakan data Podes diantaranya Parmanto dkk. (2008) menggunakan data statistik desa untuk melakukan analisis spasial dan multidimensi untuk penilaian kesehatan masyarakat. Maulana, Mochamad & Wulansari, Ika. (2021) menggunakan data podes sebagai variabel penyerta untuk penelitian *small area estimation* dalam menduga rata-rata pengeluaran per kapita di level kecamatan di Jawa Timur dan pada penelitian Tukiran, T(2016) untuk penentuan desa miskin analisis potensi desa 1990 dengan membangun indeks komposit dari variabel-variabel yang mencerminkan kemiskinan yaitu potensi dan fasilitas desa, perumahan dan lingkungan serta keadaan penduduk lalu dikelompokkan dari indeks komposit yang dibangun.

Pada data Podes 2018 pada blok ekonomi terdapat indikator-indikator yang mencerminkan kemiskinan diantaranya adalah jumlah keluarga miskin menurut kepala desa/lurah selama tahun 2017. Indikator ini dapat mencerminkan kemiskinan namun memiliki karakteristik berdasarkan pengakuan aparatur pemerintah desa/kelurahan setempat, dapat sampai pada level wilayah tingkat desa/kelurahan di seluruh Indonesia. Indikator ini berbeda dengan kemiskinan yang ada di SUSENAS (Survei Sosial Ekonomi Nasional yang mengukur kemiskinan menggunakan konsep kemampuan memenuhi kebutuhan dasar (*basic need approach*) dan hanya berada hingga level kabupaten/kota.

Pada penelitian ini Podes 2018 menjadi basis data kewilayahan sampai tingkat desa dalam memberikan informasi mengenai kemiskinan yaitu keluarga miskin. Estimator yang dihitung pada penelitian ini adalah jumlah keluarga miskin per kecamatan. Dengan *variable* pendukung yang berasal dari big data yaitu data penginderaan jarak jauh intensitas cahaya malam dalam menggambarkan aktivitas ekonomi di suatu wilayah. Beberapa penelitian menggunakan NTL dalam menggambarkan aktivitas ekonomi diantaranya Putri, Salwa & Suganda, Thosan & Pramana, Setia. (2021) menggunakan NTL dalam memodelkan kondisi ekonomi hijau Indonesia di Era Pandemi dan Penerapan *Bayesian Network* dalam Memodelkan Kondisi Ekonomi Hijau Indonesia di Era Pandemi Berdasarkan Big Data dan Noor, Abdisalan & Alegana, Victor & Gething, Peter & Tatem, Andrew & Snow, Robert. (2008) menggunakan intensitas cahaya malam sebagai *proxy* kemiskinan di Afrika.

contoh berikut pemetaan jumlah keluarga miskin pada level desa hasil Podes 2018 di Provinsi Bali seperti pada gambar 1 berikut. Pada contoh digunakan metode *equal interval* agar dapat dihasilkan lima pengelompokan.



gambar 2.2


Penggunaan Data Podes 2018 sebagai *direct estimation* pada penelitian ini memerlukan beberapa proses terlebih dahulu. Pertama perlu dilakukan matching data Podes 2018 dengan data nilai intensitas cahaya pada malam yang telah diolah menjadi nilai rata-rata per desa menggunakan kode wilayah kerja statistic level desa/kelurahan berdasarkan BPS. Data kemudian akan dilakukan pemodelan yang akan diolah pada tahap selanjutnya.

2.2 NIGHT TIME LIGHT

Data selanjutnya yang digunakan untuk melakukan estimasi kemiskinan dengan remote sensing pada kajian ini adalah data citra satelit. Citra satelit merupakan gambaran yang terekam oleh lensa kamera atau sensor yang terpasang pada wahana satelit luar angkasa dengan ketinggian lebih dari 400 km dari permukaan bumi yang menyimpan berbagai informasi yang ada di dalamnya. Penjelasan mengenai citra satelit sendiri dapat ditemukan pada buku "Teknik Pengumpulan Data dan Preprocessing Citra Satelit". Pada buku tersebut dijelaskan mengenai definisi dari citra satelit, macam-

macam data citra satelit, bagaimana cara mendapatkan data citra satelit dari berbagai sumber, dan apa saja kegunaan dari peta citra satelit. Pada kajian ini estimasi kemiskinan akan dilakukan dengan melakukan pemodelan menggunakan salah satu macam dari citra satelit yaitu citra malam atau biasa disebut Night Time Light (NTL). Pada subbab ini akan dijelaskan bagaimana citra satelit malam atau NTL diolah untuk mendapatkan rata-rata nilai intensitas cahaya pada malam hari per desa di Indonesia.


Citra malam atau NTL memiliki karakteristik data berupa nilai intensitas cahaya pada malam hari (average) pada setiap pikselnya, yang mana semakin terang suatu wilayah di malam hari maka semakin besar pula nilai intensitas cahaya pada piksel di wilayah tersebut. Gambar 2.3 merupakan contoh citra malam atau NTL di wilayah Provinsi Bali. Dapat dilihat pada gambar tersebut bahwa bagian selatan dari Provinsi Bali memiliki warna yang lebih terang dibandingkan wilayah lainnya. Hal ini menunjukkan bahwa piksel-piksel di bagian selatan dari citra malam Provinsi Bali juga akan memiliki nilai intensitas cahaya yang lebih tinggi dibandingkan piksel-piksel lainnya.



gambar 2.3 Citra Satelit Malam (Night Time Light) Provinsi Bali

Nilai intensitas cahaya pada malam hari di setiap piksel ini selanjutnya akan dikelompokkan per desa untuk kemudian didapatkan nilai rata-rata intensitas cahaya pada malam hari di semua desa di Indonesia. Untuk melakukan hal ini maka diperlukan *shapefile* batas desa di Indonesia, kemudian menempelkan atau *overlay* citra malam NTL ke *shapefile* tersebut.





METODOLOGI



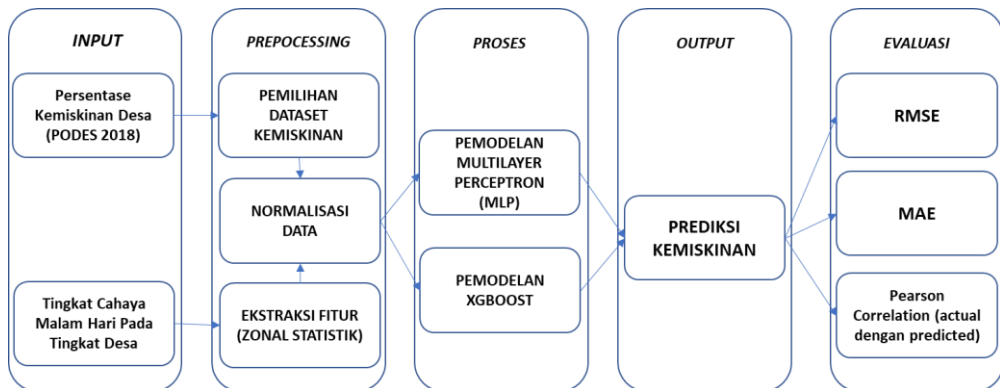
METODOLOGI

Khairunnisah, Nensi Fitria Deli

Data yang dihasilkan dari sensor citra satelit seperti citra cahaya malam hari, tidak dapat secara langsung dimodelkan melainkan perlu dilakukan transformasi data yang bergantung pada sebaran data. Sebaran data rata-rata cahaya malam di tingkat desa yang telah dijelaskan pada bab sebelumnya menggambarkan pancaran nilai cahaya malam yang umumnya berada pada nilai nol *radiance* karena dimungkinkan gelombang cahaya malam di daerah tersebut tidak tertangkap satelit sehingga diperlukan transformasi data untuk dapat menyesuaikan dengan model prediksi yang akan digunakan. Pada bab ini akan dibahas teknik transformasi data yang digunakan serta beberapa model yang digunakan untuk memprediksi tingkat kemiskinan dengan menggunakan cahaya malam hari.

3.1 DESAIN PEMODELAN

Pemodelan prediksi persentase penduduk miskin pada tingkat desa dengan citra satelit pada publikasi ini menggunakan dua teknik pemodelan dengan alur perancangan pemodelan sebagai berikut :




Gambar 3.1 Alur Perancangan Pemodelan Prediksi Persentase Kemiskinan pada tingkat desa



Pada publikasi ini digunakan data persentase rumah tangga miskin pada tingkat desa menggunakan sumber data Survei Potensi Desa (Podes) 2018. Selanjutnya pada tahapan pemilihan *dataset* kemiskinan, dilakukan pengujian hubungan antara tingkat cahaya malam dengan persentase kemiskinan menggunakan korelasi pearson untuk melihat hubungan linier antara kedua variabel tersebut. Pada penelitian ini digunakan *dataset* menurut provinsi yang memiliki tingkat korelasi yang tinggi antara cahaya malam dengan persentase kemiskinan pada tingkat desa. Setelah pemilihan dataset kemiskinan dilakukan normalisasi data yang sangat menceng menjadi kurang menceng serta bermanfaat untuk membuat pola data lebih dekat dengan distribusi normal dan dilakukan pemodelan menggunakan model *machine learning* yang meliputi *Decision Tree Regression*, *Random Forest Regression*, *Support Vector Regression*, *Multilayer Perceptron Regression*, dan *XGBoost Regression*. Untuk membandingkan hasil prediksi kemiskinan yang terbaik dilakukan perbandingan RMSE dari setiap pemodelan.


3.2 EKSTRAKSI FITUR

Ekstraksi fitur merupakan suatu pengambilan ciri (*feature*) dari suatu bentuk yang nantinya nilai yang didapatkan akan dianalisis untuk proses selanjutnya. Pada publikasi ini ekstraksi fitur dilakukan untuk mengubah dataset yang semula berbentuk raster citra satelit malam (NTL) ke dalam bentuk vektor tabel dengan metode *Zonal Statistics*. Metode *Zonal Statistics* ini memungkinkan kita untuk melakukan operasi statistik (*median*, *mean*, *max*, dan *min*) dari nilai sel di sebuah raster dalam zona yang ditentukan oleh kumpulan data lain, dalam hal ini zona yang ditentukan menggunakan data Batas Desa Seluruh Indonesia Tahun 2018 berformat *shapefile*. Untuk melakukan metode *Zonal Statistics*, data *shapefile* akan digunakan sebagai layer dalam membuat dan menentukan batas-batas desa pada raster citra satelit malam. Sebagai contoh, berikut merupakan layer *shapefile* yang menampilkan batas desa di Provinsi Bali tahun 2018.



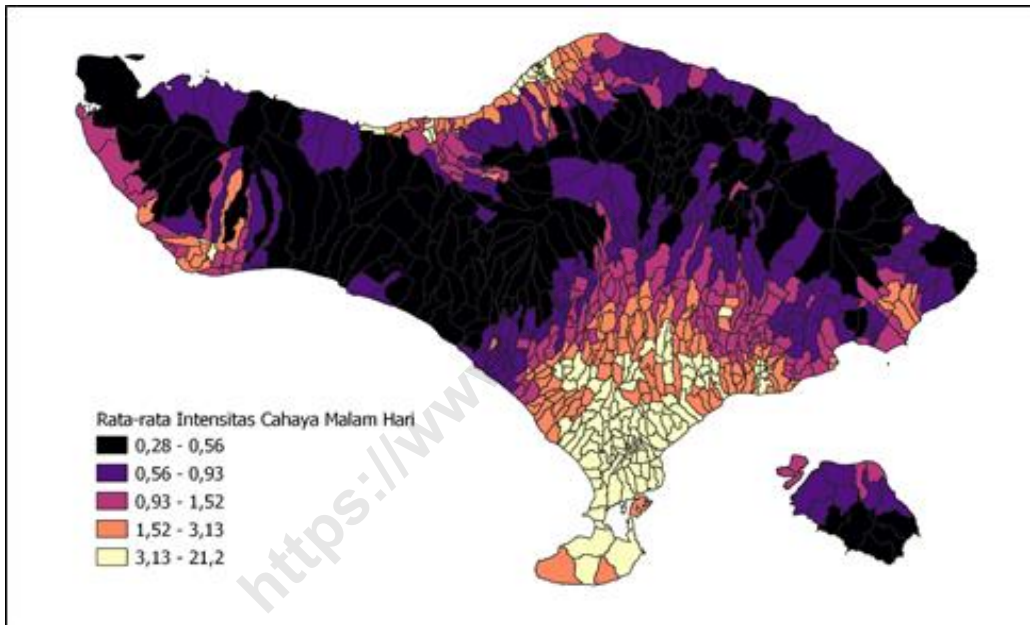
Gambar 3.2 *Shapefile* Batas Desa Provinsi Bali Tahun 2018

Selanjutnya pada raster citra satelit malam Provinsi Bali ditambahkan garis-garis batas desa dari *shapefile* Provinsi Bali sehingga bentuk raster citra satelit malam Provinsi Bali akan seperti pada gambar berikut.



Gambar 3.3 Raster Citra Satelit Malam Provinsi Bali yang sudah ditambahkan layer Garis Batas Desa Tahun 2018

Setelah mendapat raster citra satelit malam yang telah diberi garis batas desa, barulah metode *Zonal Statistics* dapat dilakukan. Dalam kasus ini nilai statistik yang dioperasikan adalah nilai intensitas cahaya pada malam hari di setiap piksel citra satelit malam. Nilai tersebut akan dirata-ratakan sesuai zona yang telah ditentukan, yaitu batas desa di setiap desa di Provinsi Bali. Hasil dari metode *Zonal Statistics* adalah peta Provinsi Bali per desa yang telah memiliki nilai rata-rata intensitas cahaya pada malam hari di setiap desanya seperti pada gambar 5 di bawah.




Gambar 3.4. Rata-rata Intensitas Cahaya pada Malam Hari di Provinsi Bali per Desa Tahun 2018

Rata-rata nilai intensitas cahaya pada malam hari per desa ini yang selanjutnya akan diolah pada tahap selanjutnya.

3.3 TRANSFORMASI DATA

Setelah dipetakan pada grafik distribusi frekuensi (Gambar 3.2), diketahui bahwa rata-rata cahaya malam yang akan diolah didominasi oleh nilai 0 (nol) dan mendekati 0 *radianse*, yang berarti citra cahaya malam yang diolah didominasi oleh wilayah yang pencahayaannya gelap atau yang cahaya malam di wilayah tersebut tidak dapat ditangkap oleh satelit. Karena didominasi oleh nilai nol, maka variabel rata-rata cahaya malam perlu ditransformasi agar variabel tersebut bisa dimasukkan ke dalam model prediksi yang akan digunakan. Transformasi data yang digunakan pada publikasi ini adalah transformasi logaritma.



Gambar 3.2. Distribusi frekuensi rata-rata cahaya malam seluruh Indonesia

Transformasi logaritma merupakan salah satu metode transformasi yang mengganti nilai variabel x menjadi $\log(x)$. Metode ini bisa digunakan untuk membuat data yang sangat menceng menjadi kurang menceng (Lane et al., 2003). Hal ini bisa bermanfaat untuk membuat pola data lebih mudah diinterpretasikan. Rumus yang digunakan untuk melakukan transformasi ini adalah sebagai berikut:

$$x' = \log(x)$$

dimana:

x adalah data sebelum ditransformasi, dan

x' adalah data setelah ditransformasi.

Pada penelitian ini, data yang akan ditransformasi adalah data rata-rata cahaya malam. Namun, variabel ini mengandung nilai nol. Untuk menghindari hasil transformasi bernilai tak hingga (dimana $\log(0) = \infty$), maka data yang ditransformasi adalah $x+1$. Berdasarkan penelitian yang dilakukan, penggunaan $+1$ cukup membantu untuk mengatasi transformasi log terhadap variabel yang mengandung nilai 0. Sehingga rumus yang digunakan untuk transformasi pada penelitian ini menjadi:

$$x' = \log(x+1)$$

3.4 NORMALISASI DATA

Normalisasi data merupakan salah satu Langkah efektif untuk meningkatkan akurasi beberapa *machine learning* tertentu (S. K. Dey et al., 2018), termasuk *Artificial Neural network* (ANN) yang merupakan model prediksi yang digunakan pada publikasi ini. Metode normalisasi data yang digunakan adalah Min-Max Scaler (MMS). MMS menskalakan data menjadi rentang 0-1 dengan rumus yang digunakan adalah sebagai berikut:

$$y_i = \frac{x_i - \min_x}{\max_x - \min_x}$$

dimana:

y_i adalah data yang telah distandarisasi untuk desa ke- i dalam wilayah provinsi

x_i adalah data untuk desa ke- i dalam wilayah provinsi

i adalah desa dalam satu provinsi

\min_x adalah nilai minimum dalam wilayah provinsi

\max_x adalah nilai maksimum dalam wilayah provinsi

3.5 MODEL PREDIKSI DENGAN MACHINE LEARNING

Pada publikasi ini, prediksi tingkat kemiskinan pada tingkat desa dilakukan dengan menggunakan beberapa algoritma di antaranya metode *Decision Tree Regression*, *Random Forest Regression*, *Support Vector Regression*, *Multilayer Perceptron Regression*, dan *XGBoost Regression*. Kedua pemodelan ini dilakukan untuk mendapatkan akurasi tertinggi dalam memprediksi kemiskinan dengan tingkat *error* seminimal mungkin.


3.5.1. MULTILAYERPERCEPTION (MLP) REGRESSION

Multilayer perceptron (MLP) atau *Multilayer Neural network* merupakan artificial *neural network feed-forward* yang memiliki sejumlah neuron atau saraf yang saling terhubung dengan neuron lainnya melalui neuron bobot penghubung. Neuron pada MLP dibagi dalam beberapa *layer* diantaranya *input layer*, *hidden layer*, dan *output layer*. Pada MLP terdapat banyak *hidden layer* yang terletak diantara ruang *input* dan *output layer*. MLP diperkenalkan oleh Marvin Minsky dan Seymour Paper pada tahun 1969 untuk mengatasi kelemahan *perceptron* dalam melakukan klasifikasi *input* non linear (Riedmiller, 1994). Selain itu MLP merupakan metode *neural network* yang sering digunakan dalam pemodelan *forecasting*. MLP memiliki keunggulan dalam kemudahan implementasi algoritma tanpa memerlukan pengetahuan sebelumnya dan dapat menghasilkan nilai akurasi yang lebih baik dibandingkan metode lainnya, serta mampu menyelesaikan permasalahan linearitas pada data (Park & Lek, 2016; Riedmiller, 1994). Akan tetapi MLP juga memiliki kekurangan

dalam akumulasi *error* yang dihasilkan setiap *layer* dan mempengaruhi proses bobot



sampai pada lapisan *output*. Karakteristik tersebut menjadikan MLP lebih unggul dalam melakukan peramalan dibandingkan model lainnya.



Gambar 3.3. Arsitektur *Feed Forward* MLP dengan dua *layer* bobot adaptif (Marwala, 2018)

Pemodelan *multilayer perceptron* (MLP) pada publikasi ini dilakukan untuk memprediksi persentase penduduk miskin pada tingkat wilayah administrasi desa dengan menggunakan tingkat cahaya malam. Gambar 1 menjelaskan arsitektur yang digunakan pada publikasi ini. Simbol N_1 dan N_2 adalah *node* untuk *input layer*. Nilai z_0 merupakan nilai bias, sedangkan N_3 dan N_4 adalah *node* untuk *hidden layer* dan N_5 dan N_6 adalah *node* untuk *output layer*. Algoritma pembelajaran memprediksi persentase penduduk miskin pada tingkat desa dengan menggunakan *multilayer perceptron* dilakukan sebagai berikut :

Tahap 0 (*input*) :

- Melakukan *input* data Latihan pada jaringan

Tahap 1 (inisiasi) :

- Melakukan inisiasi dengan nilai acak terkecil pada bobot
- Melakukan pengaturan parameter seperti menetapkan *Learning rate* dan *momentum coefficient*

Tahap 2 (training loop) :

- Menerapkan pola *input network* pada *input layer*

Tahap 3 (*forward propagation*) :

- Mendistribusikan sinyal *forward* melalui jaringan
- Menghitung *network output vector*. Tahap 4

(Menghitung *Output error*) :

- Menghitung *error* pada setiap *output* (menghitung selisih antara target dengan *network input*).

Tahap 5 (*error backpropagation*) :

- Mendistribusikan *error backward* untuk menyesuaikan bobot dengan cara meminimalkan *error*.

Tahap 6 (satu *loop iteration*) :

- Memeriksa apakah seluruh data telah digunakan
- Mengulangi tahap dua dengan menggunakan tahap 5 untuk seluruh *training dataset*.

3.5.2. Extreme Gradient Boosting (XGBoost) Regression

XGboost merupakan salah satu teknik *supervised machine learning* yang digunakan dengan tujuan optimasi *gradient boosting* untuk mempercepat proses komputasi dan menghindari *overfitting*. XGBoost pertama kali diperkenalkan oleh Chen & Guestrin pada tahun 2016 (Chen & Guestrin, 2016) sebagai perbaikan dari metode *gradient boosting* yang telah pertama kali diperkenalkan oleh Friedman pada tahun 2001. (Friedman, Jerome H, 2001).

Selain itu, algoritma XGBoost juga mengurangi kompleksitas dalam menentukan split terbaik pada *decision tree*. Dalam prosesnya XGBoost memerlukan beberapa parameter sebagai dasar implementasinya sebagai berikut:

1. *Learning rate* (η) atau ukuran *shrinkage*. Nilai ini memiliki rentang nilai 0 sampai 1 dan memiliki nilai bawaan 0.3. Nilai ini digunakan untuk mencegah *overfitting* pada model. Nilai yang lebih tinggi menghasilkan pohon yang lebih sederhana. Nilai ini mengontrol perolehan nilai *gain* yang diperlukan untuk membagi simpul internal.
2. *Minimum loss reduction* (γ). Semakin besar nilai γ maka *decision tree* yang terbentuk akan semakin dangkal. γ memiliki rentang nilai 0 sampai tak terhingga dan memiliki nilai bawaan 0.
3. *Maximum depth of tree* (max_depth). Max_depth menunjukkan kedalaman pohon. Pohon yang semakin dalam dapat meningkatkan kinerja namun juga dapat meningkatkan kompleksitas, nilainya harus lebih besar dari 0 dan nilai bawaannya adalah $Colsample_bytreel$ adalah persentase $ftur$ yang digunakan per pohon. Nilai yang tinggi dapat menyebabkan *overfitting*. Nilainya berada pada rentang 0 sampai dengan 1 dengan nilai bawaannya adalah 1.
4. *Subsample* adalah persentase sampel yang digunakan per pohon. Nilai yang rendah dapat menyebabkan *underfitting*. Nilainya berada antara 0 dan 1 dengan nilai bawaannya adalah 1.
5. λ dan α . Nilai ini adalah istilah *regularisasi* pada bobot. Nilai bawaan

λ diasumsikan adalah 1 dan α adalah 0. Jika dibandingkan dengan ada *boost* dan *gradient boosting*, algoritma *XGBoost* adalah algoritma yang paling baik untuk pemodelan regresi data sekuensial seperti time series.

3.6. Evaluasi Keباikan Model

Pada publikasi ini diterapkan model *Xgboost* dan *MLP* untuk memprediksi kemiskinan pada tingkat desa. Dalam menentukan kebaikan antara kedua model yang digunakan dilakukan beberapa metode diantaranya *Root Mean Square Error (RMSE)*, *Mean Absolute Percentage Error (MAPE)*, dan korelasi *Pearson* antara nilai prediksi kemiskinan dengan nilai yang sebenarnya.

3.6.1 Root Mean Square Error (RMSE)

RMSE merupakan akar kuadrat dari MSE (*Mean Square Error*) yang digunakan untuk mengetahui variasi *error* pada nilai prediksi. Penerapan MSE dalam pemodelan berpengaruh pada dataset yang memiliki *outlier*. *Mean Absolute Error (MAE)* dan *Root Mean Square Error (RMSE)* merupakan ukuran akurasi yang menunjukkan korespondensi rata-rata antara pasangan individual pada nilai prediksi dan aktual. Model prediksi dapat berkategori baik apabila nilai MAE maupun RMSE mendekati 0 (nol). MAE dan RMSE secara bersama dapat digunakan untuk mengetahui variasi error pada nilai *forecast*. Pada publikasi ini nilai RMSE dihitung dengan menggunakan persamaan sebagai berikut :

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

dimana :

y_i adalah nilai persentase kemiskinan actual pada desa ke-i dalam wilayah provinsi

\hat{y}_i adalah nilai prediksi persentase kemiskinan pada desa ke-i dalam wilayah provinsi

n adalah jumlah desa dalam satu provinsi

3.6.2 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan ukuran yang menggambarkan keakuratan dari nilai prediksi yang dihasilkan dari pemodelan. Mean Absolute Error (MAE) diperoleh dengan menghitung nilai selisih mutlak antara nilai sebenarnya (actual) dengan nilai prediksi dari pemodelan. Nilai MAE dapat digunakan untuk membandingkan dua model atau lebih dalam melakukan peramalan. Semakin baik model yang digunakan untuk melakukan peramalan akan semakin kecil nilai MAE yang dihasilkan. Pada publikasi ini nilai MAE dihitung dengan menggunakan persamaan sebagai berikut :

$$MAE = \left(\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \right) * 100$$

dimana :

y_i adalah nilai persentase kemiskinan *actual* pada desa ke- i dalam wilayah provinsi

\hat{y}_i adalah nilai prediksi persentase kemiskinan pada desa ke- i dalam wilayah provinsi

n adalah jumlah desa dalam satu provinsi

i adalah desa dalam satu provinsi

3.6.3 Korelasi Pearson (r)

Korelasi Pearson merupakan salah satu pengukuran statistik yang digunakan untuk melihat keeratan hubungan linear antara dua variabel dalam skala data interval atau rasio. Pada publikasi ini dilakukan korelasi antara persentase kemiskinan actual (y) dengan prediksi persentase kemiskinan (\hat{y}) dari hasil pemodelan. Korelasi Pearson (r) pada publikasi ini dihitung dengan menggunakan persamaan berikut :

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

dimana :

y_i adalah nilai persentase kemiskinan *actual* pada desa ke- i dalam wilayah provinsi

\hat{y}_i adalah nilai prediksi persentase kemiskinan pada desa ke- i dalam wilayah provinsi

i adalah desa dalam satu provinsi

n adalah jumlah desa dalam satu provinsi



IV





ANALISIS HASIL PEMODELAN ESTIMASI KEMISKINAN DENGAN *XGBOOST* DAN MLP

Dhiar Niken Larasati, Dewi Lestari Amaliah

4.1. ANALISIS MODEL

4.1.1. Akurasi Prediksi

Akurasi dari model yang bertujuan untuk memprediksi suatu variabel sangat penting untuk mengevaluasi kualitas dari prediksi yang dihasilkan, terlebih lagi jika nilai prediksi tersebut akan digunakan untuk pengambilan keputusan atau penyusunan kebijakan (Li 2017). Dengan demikian, sangat penting untuk melihat bagaimana akurasi MLP dan *XGBoost* dalam memprediksi tingkat kemiskinan di setiap provinsi di Indonesia.

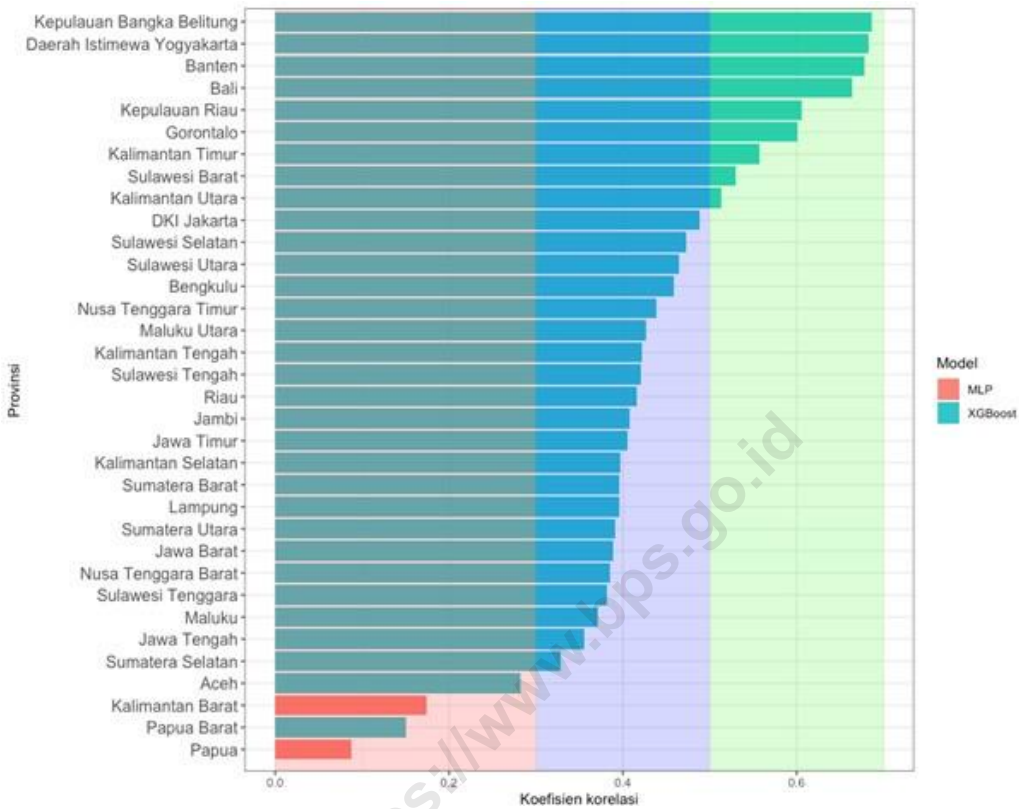
Salah satu ukuran yang sering digunakan untuk melihat akurasi model adalah koefisien korelasi Pearson r (Li 2017). Dalam konteks ini, ukuran ini menunjukkan korelasi antara persentase tingkat kemiskinan hasil prediksi dengan menggunakan model MLP atau *XGBoost* dengan persentase kemiskinan aktual berdasarkan data PODES 2018. Idealnya, ketika prediksi yang dihasilkan akurat, maka koefisien korelasi akan semakin besar dan bernilai positif. Secara lebih rinci, interpretasi dari koefisien korelasi adalah sebagai berikut (Hinkle, Wiersma & Jurs 2003 dalam Mukaka 2012):



- 0,90 hingga 1,00 (-0,90 hingga -1,00) menunjukkan korelasi positif (negatif) yang sangat kuat;
- 0,70 hingga 0,89 (-0,70 hingga -0,89) menunjukkan korelasi positif (negatif) yang kuat;
- 0,50 hingga 0,69 (-0,50 hingga -0,69) menunjukkan korelasi positif (negatif) yang moderat;
- 0,30 hingga 0,49 (-0,30 hingga -0,49) menunjukkan korelasi positif (negatif) yang lemah;
- 0,00 hingga 0,29 (-0,00 hingga -0,29) menunjukkan bahwa korelasinya bisa diabaikan atau tidak terdapat korelasi.

Berdasarkan Gambar 4.1, terlihat bahwa akurasi prediksi yang dihasilkan berbeda-beda di setiap provinsi. Beberapa provinsi memiliki korelasi yang moderat (cukup kuat) yang ditandai oleh area berwarna hijau, misalnya Kepulauan Bangka Belitung, Bali, dan Kalimantan Utara. Kebanyakan provinsi berada pada kriteria korelasi yang lemah, ditandai dengan batangan grafik yang ditutupi oleh area berwarna biru. Sementara itu, terdapat empat provinsi dengan korelasi yang sangat lemah yaitu Provinsi Aceh, Kalimantan Barat, Papua, dan Papua Barat.

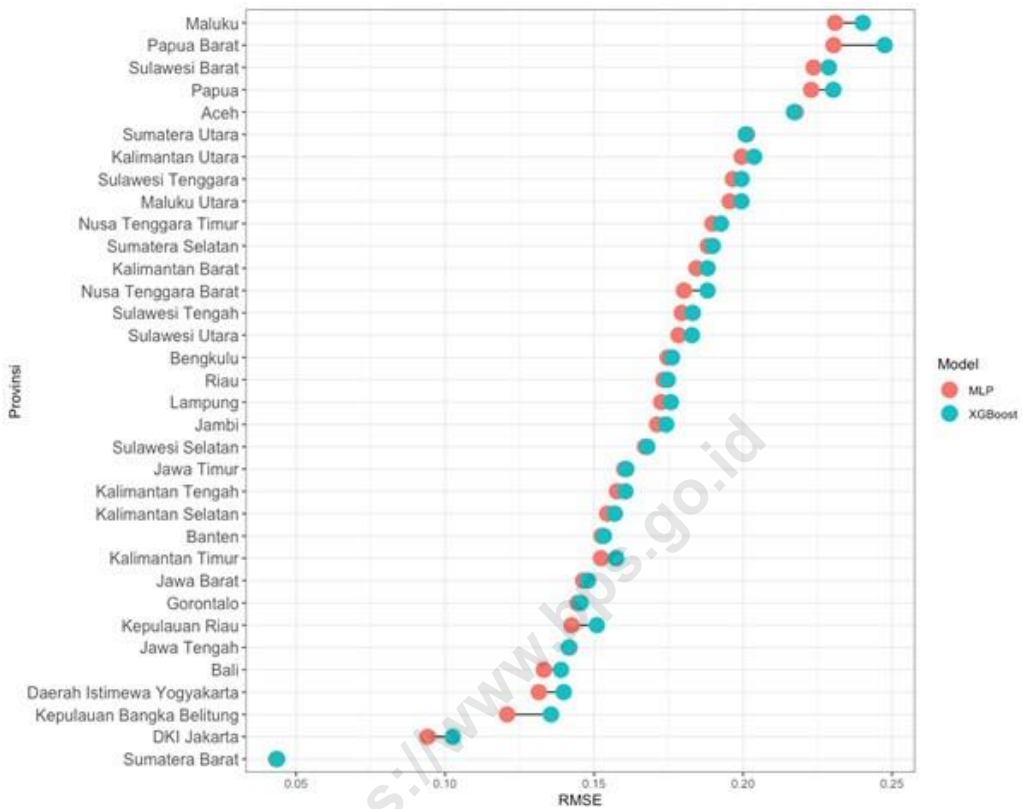
Berdasarkan jenis model yang digunakan, terlihat bahwa model yang memberikan korelasi yang lebih tinggi lebih banyak dihasilkan oleh model *XGBoost*. Hasil t-test pada Tabel 4.1. juga menunjukkan bahwa nilai korelasi *XGBoost* secara signifikan berbeda dengan nilai korelasi MLP (Alpha: 5\%).



Gambar 4.1. Koefisien korelasi antara persentase kemiskinan hasil prediksi dengan persentase kemiskinan aktual (data PODES 2018). Area berwarna biru, biru, dan hijau masing-masing menunjukkan korelasi yang sangat lemah, lemah, dan moderat. Terlihat bahwa akurasi prediksi berbeda-beda di setiap provinsi, dan korelasi tertinggi lebih banyak dihasilkan oleh model *XGBoost*.

4.1.2. Kinerja Model

Berdasarkan analisis sebelumnya, dengan menggunakan koefisien korelasi sebagai indikator akurasi, dapat disimpulkan bahwa nilai prediksi tingkat kemiskinan dengan menggunakan NTL belum begitu akurat dalam merepresentasikan persentase kemiskinan yang sebenarnya. Oleh karena itu, juga penting untuk melihat bagaimana kinerja dari kedua model yang digunakan dengan ukuran yang lain, yaitu *Root Mean Square Error* (RMSE) (Li 2017). RMSE adalah penjumlahan dari *variance* dan bias. Oleh karena itu, apabila suatu estimator dianggap *unbiased*, maka RMSE hanya mewakili σ dari suatu estimator (EUROSTAT 2019). RMSE dapat digunakan untuk membandingkan model. Semakin kecil nilai RMSE, maka kinerja model semakin baik. Dengan kata lain, apabila terdapat dua model, model yang lebih baik adalah model dengan RMSE yang lebih kecil. Gambar 4.2 menunjukkan perbandingan RMSE model MLP dan *XGBoost* untuk masing-masing provinsi di Indonesia.



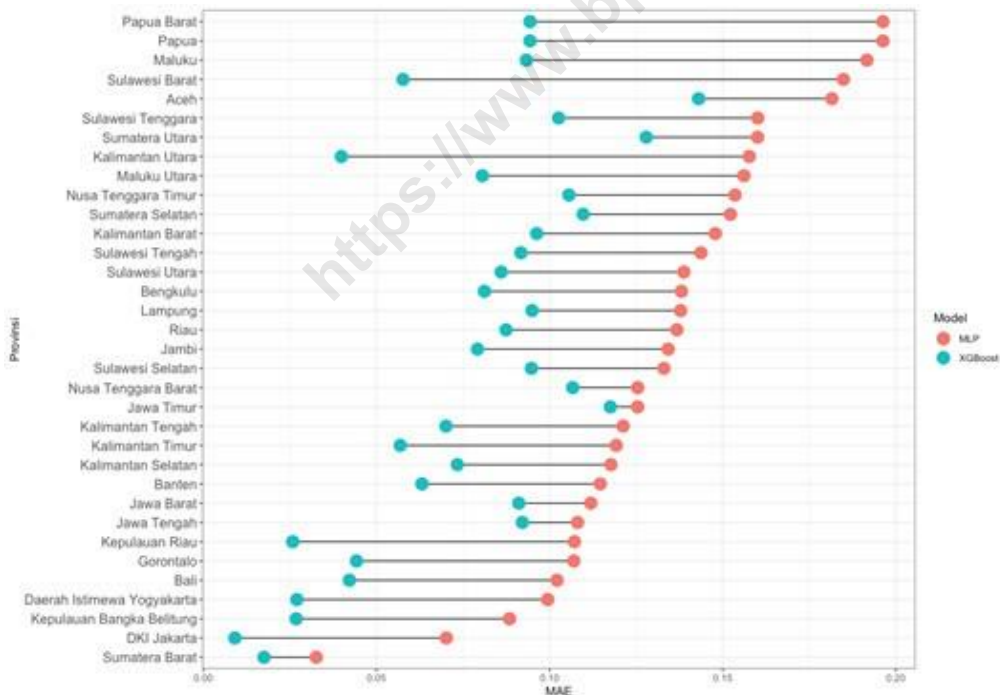
Gambar 4.2. Perbandingan RMSE model MLP dan XGBoost untuk memprediksi kemiskinan dengan menggunakan NTL pada 34 provinsi di Indonesia. Secara umum, kinerja model MLP lebih baik dari model XGBoost meskipun selisihnya tidak begitu jauh.

Gambar 4.2. menunjukkan bahwa nilai RMSE bervariasi antar-provinsi. Lima provinsi dengan RMSE paling rendah adalah Sumatera Barat, DKI Jakarta, Kepulauan Bangka Belitung, Daerah Istimewa Yogyakarta, dan Bali. Apabila kita kembali melihat kembali nilai koefisien korelasinya, beberapa provinsi tersebut juga berada pada kategori korelasi yang cukup kuat. Provinsi-provinsi tersebut adalah Kepulauan Bangka Belitung, Daerah Istimewa Yogyakarta, dan Bali. Sebaliknya, juga terdapat beberapa provinsi yang berada di antara provinsi dengan nilai RMSE tertinggi sekaligus memiliki koefisien korelasi paling rendah. Provinsi-provinsi tersebut adalah Papua, Papua Barat, dan Aceh.

Selain itu, Gambar 4.2. juga mengindikasikan bahwa secara umum, RMSE model MLP lebih kecil daripada model XGBoost meskipun selisihnya tidak terlalu besar. Pun dengan menggunakan t-test, tidak ada perbedaan signifikan antara RMSE XGBoost dengan MLP.

Dalam studi ini, kinerja model juga dinilai dengan menggunakan MAE. Berbeda dengan RMSE, kinerja model akan lebih terbanding dan memiliki benchmark karena nilainya hanya ada pada rentang 0 hingga 1. Semakin kecil MAE model, maka semakin baik model tersebut. Secara umum, MAE model untuk keseluruhan provinsi berkisar antara 0,03 hingga 0,2. Nilai ini cukup kecil sehingga dapat dikatakan bahwa secara umum model yang dihasilkan memiliki kinerja yang cukup baik.

Pada Gambar 4.3, dapat kita lihat bahwa terdapat perbedaan yang cukup besar antara MAE model XGBoost dan MLP. Perbedaan MAE antara model XGBoost dan MLP juga signifikan secara statistik dengan menggunakan uji t-test dengan tingkat error 5%. Secara umum, model XGBoost menghasilkan prediksi dengan error yang lebih kecil. Sama halnya dengan RMSE, dengan menggunakan MAE, kita dapat melihat bahwa Sumatera Barat, DKI Jakarta, Kepulauan Bangka Belitung, Daerah Istimewa Yogyakarta, dan Bali adalah provinsi-provinsi dengan MAE terkecil. Sementara itu, agak sedikit berbeda dengan RMSE, provinsi dengan MAE terbesar ditunjukkan oleh Papua Barat dan Papua.



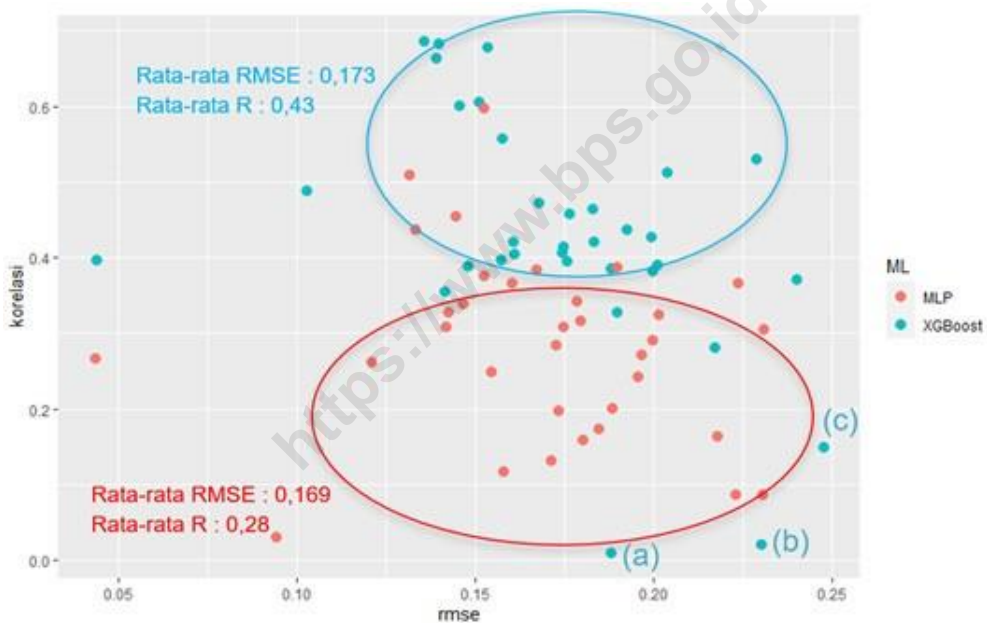
Gambar 4.3. Perbandingan MAE model MLP dan XGBoost untuk memprediksi kemiskinan dengan menggunakan NTL pada 34 provinsi di Indonesia. Secara umum, kinerja model MLP lebih baik dari model XGBoost.

Tabel 4.1. Hasil t-test perbedaan antara model MLP dan XGBoost dengan Alpha 5% menurut ukuran akurasi dan kinerja model.

Ukuran	t-value	p-value
Koefisien korelasi	-4.1914	8,862e-05
RMSE	-0,44011	0,6613
MAE	-6,8402	3,209e-09

4.1.3. Analisis Kinerja Model-Akurasi Prediksi

Analisis Kinerja Model-Akurasi Prediksi dilakukan untuk menangkap apakah model yang dihasilkan cukup baik dilihat dari kinerja model (RMSE) maupun akurasi prediksi (koefisien korelasi nilai prediksi dan aktual (R)).



Gambar 4.4. Perbandingan Model XGBoost dan MLP. Model XGBoost secara umum memberikan prediksi persentase kemiskinan dengan korelasi terhadap persentase kemiskinan aktual yang lebih tinggi dibandingkan dengan Model MLP.


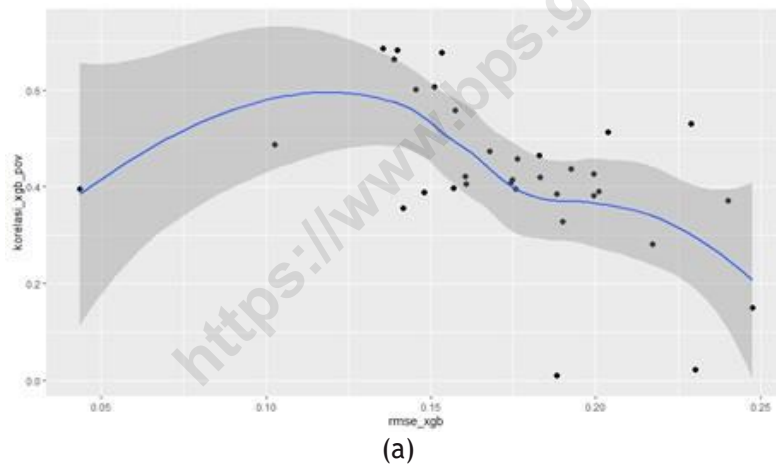
Gambar 4.4. menggambarkan relasi antara koefisien korelasi dan RMSE dari model XGBoost dan MLP semua provinsi di Indonesia. Model XGBoost dan MLP terlihat membentuk kluster. Kluster model XGBoost secara umum memberikan nilai koefisien korelasi yang lebih tinggi dibandingkan dengan kluster model MLP. Hal ini menunjukkan bahwa untuk kasus di Indonesia, model XGBoost secara umum lebih baik dalam menggambarkan pola kemiskinan yang lebih sesuai dengan pola kemiskinan desa yang sesungguhnya. Sedangkan jika melihat dari performansi, kedua model tersebut tampak memberikan kinerja yang sama baiknya ditunjukkan dari nilai RMSE kedua model secara rata-rata tidak terlalu berbeda signifikan, hal ini ditunjukkan

dengan hasil *t-test* pada pembahasan sebelumnya (Tabel 4.1). Walaupun secara umum

memberikan performansi yang lebih baik, ada beberapa provinsi yang memberikan hasil kurang baik ketika menerapkan model *XGBoost*, yaitu Kalimantan Barat (a), Papua (b), dan Papua Barat (c). Model untuk ketiga provinsi ini memberikan nilai koefisien korelasi yang cukup rendah dan RMSE yang cukup tinggi.

4.1.4. Analisis Kestabilan Performansi Model

Kestabilan performansi setiap model diperlihatkan oleh Gambar 4.5. Model dapat dikatakan stabil dalam performansi jika sebaran model dapat memberikan nilai RMSE yang kecil dan korelasi yang besar atau sebaliknya. Sebaran RMSE dan koefisien korelasi dari 34 model estimasi kemiskinan dengan *XGBoost* terlihat memberikan arah berkebalikan yang ditunjukkan oleh *slope* menurun dimana hal ini sesuai dengan konsep kestabilan performansi model. Model *XGBoost* yang dapat memberikan prediksi pola kemiskinan yang sesuai dengan pola kemiskinan aktual (koefisien korelasi tinggi) cenderung memberikan kinerja model yang juga baik (RMSE rendah), demikian sebaliknya (Gambar 4.5. (a)).



Gambar 4.5. Kestabilan Performansi Model (a) *XGBoost* (b) MLP. Untuk kasus Indonesia model

XGB cenderung memberikan kestabilan performansi yang lebih baik dibandingkan dengan model MLP

Di sisi lain, sebaran model MLP terlihat lebih bervariasi dari sisi RMSE namun cenderung stabil untuk nilai koefisien korelasi. Dapat dikatakan bahwa untuk kasus Indonesia, model MLP yang menunjukkan kinerja model yang lebih baik (RMSE kecil) belum tentu akan memberikan prediksi pola kemiskinan yang lebih sesuai dengan kondisi aktual (koefisien korelasi besar). Secara umum, untuk kasus Indonesia dapat dikatakan model *XGBoost* memiliki kestabilan performansi model yang lebih baik dibandingkan dengan MLP.

4.2. HASIL ESTIMASI KEMISKINAN BEBERAPA PROVINSI


4.2.1. Hasil Estimasi Kemiskinan Provinsi yang Sesuai dengan Kondisi Aktual

Model kemiskinan desa di Provinsi D.I. Yogyakarta memberikan hasil yang cukup baik menurut nilai akurasi dan kinerja model. Tabel 4.2 menunjukkan secara detail performansi model kemiskinan desa di Provinsi D.I Yogyakarta. Nilai RMSE model *XGBoost* untuk D.I. Yogyakarta adalah 0,14 dan untuk model MLP sebesar 0,13. Hasil estimasi model *XGBoost* memberikan gambaran pola kemiskinan desa di D.I Yogyakarta secara moderat cenderung kuat, ditunjukkan oleh nilai koefisien korelasi aktual-prediksi sebesar 0,68. Di sisi lain, model MLP memberikan gambaran pola kemiskinan desa di D.I Yogyakarta secara moderat cenderung lemah dengan nilai koefisien korelasi sebesar 0,51. Dari hasil tersebut, dapat disimpulkan model *XGBoost* memberikan nilai estimasi kemiskinan desa di Provinsi D.I Yogyakarta lebih baik dibandingkan dengan model MLP.

Tabel 4.2 Nilai Akurasi dan Kinerja Model Kemiskinan Desa Provinsi D.I. Yogyakarta Menurut Jenis Model


Model	RMSE	Koefisien Korelasi Aktual-Prediksi
XGBoost	0,14	0,68
MLP	0,13	0,51


Gambar 4.6 menunjukkan sebaran estimasi persentase kemiskinan dari model *XGBoost* dengan persentase kemiskinan aktual dari PODES 2018 disandingkan dengan garis $y=x$ (45 derajat) untuk melihat kesesuaian antara nilai prediksi dengan nilai aktual. Nilai prediksi dikatakan akurat menggambarkan nilai aktual jika sebarannya berada di sekitar garis $y=x$. Berdasarkan penjelasan ini, dapat dikatakan bahwa model *XGBoost* secara umum sudah cukup baik dalam memprediksi persentase kemiskinan desa menurut PODES 2018, walaupun tampak ada beberapa prediksi yang sangat *underestimate* (ditunjukkan dari beberapa titik yang sangat jauh dari garis $x=y$)



Gambar 4.6. Relasi persentase kemiskinan desa menurut PODES 2018 di Provinsi D.I. Yogyakarta dengan prediksi persentase desa di Provinsi D.I Yogyakarta dengan model *XGBoost* disandingkan dengan garis $y=x$.

Perbandingan pola sebaran kemiskinan di D.I. Yogyakarta menurut PODES 2018 dan hasil pemodelan *XGBoost* ditunjukkan oleh Gambar 4.8.





Gambar 4.7. Pola Sebaran Estimasi Kemiskinan Desa (a) Aktual dan (b) Prediksi *XGBoost* di Provinsi D.I Yogyakarta

Dengan nilai koefisien korelasi persentase kemiskinan aktual dan prediksi sebesar 0,68 (lih. Tabel 4.2), hasil prediksi model *XGBoost* menunjukkan kemiripan pola di beberapa wilayah, terutama pada wilayah yang ditunjukkan oleh kode (i) dan (ii). Kode (i) adalah wilayah kota Yogyakarta dan sekitarnya. Persentase kemiskinan di wilayah ini tampak cukup rendah ditandai oleh warna yang relatif terang. Di sisi lain, persentase kemiskinan di wilayah Kab. Gunung Kidul (lih. kode (ii)) tampak relatif tinggi ditunjukkan oleh warna yang relatif gelap. Tabel 4.3 memberikan penjelasan dari hasil prediksi ini. Rata-rata nilai NTL di Kota Yogyakarta (kode 3471) memberikan nilai paling tinggi sehingga prediksi kemiskinan di wilayah tersebut menjadi yang paling rendah. Sebaliknya, rata-rata nilai NTL di Kabupaten Gunung Kidul (kode 3403) memberikan nilai yang paling rendah sehingga prediksi kemiskinan di wilayah tersebut menjadi yang paling tinggi.

Di sisi lain, prediksi kemiskinan dari model *XGBoost* tampak menunjukkan performansi yang cukup rendah untuk wilayah Kabupaten Sleman (lih. kode (iii)). Hasil prediksi model *XGBoost* untuk wilayah Kabupaten Sleman tampak *underestimate* atau lebih rendah dibandingkan dengan angka kemiskinan aktual dari PODES 2018.

Tabel 4.3. Statistik Deskriptif Data Cahaya Malam Provinsi D.I. Yogyakarta

Kode Kab/Kota	Min	Max	Mean	Varians
3401	0.25	4.57	0.90	0.34
3402	0.47	10.82	2.77	6.00
3403	0.22	4.09	0.67	0.31
3404	0.75	15.79	3.11	7.55
3471	10.03	36.60	19.93	37.71

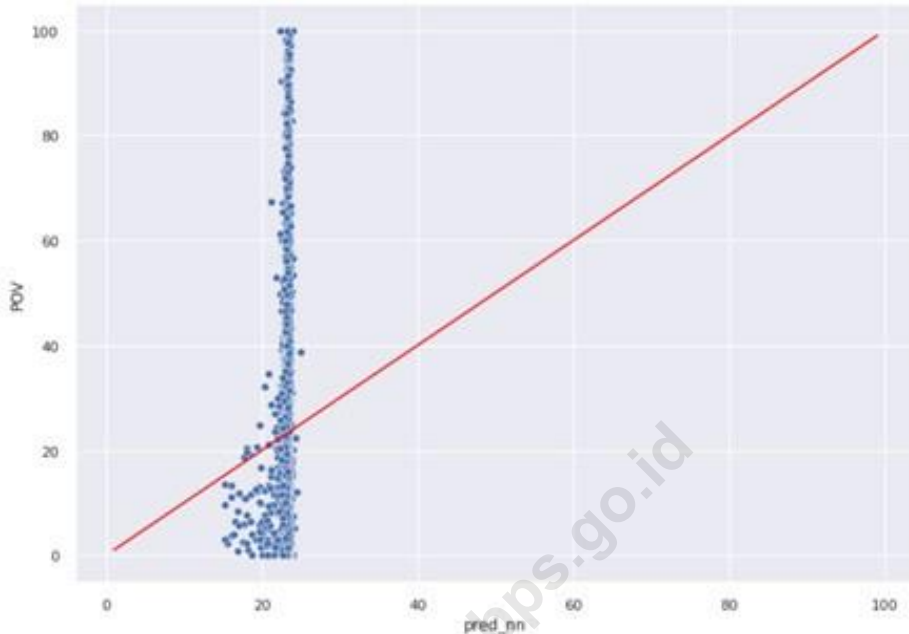
4.2.2. Hasil Estimasi Kemiskinan Provinsi yang Tidak Sesuai dengan Kondisi Aktual

Model kemiskinan desa untuk Provinsi Kalimantan Barat adalah salah satu model yang memberikan performansi yang buruk. Performansi model *XGBoost* dan MLP untuk Provinsi Kalimantan Barat ditunjukkan oleh Tabel 4.4. Dari kedua model yang diterapkan, model MLP tampak memberikan performansi yang sedikit lebih baik dibandingkan dengan model *XGBoost*, ditunjukkan dari koefisien korelasi aktual-prediksi yang lebih tinggi.

Tabel 4.4. Nilai Akurasi dan Kinerja Model Kemiskinan Desa Provinsi Kalimantan Barat Menurut Jenis Model

Model	RMSE	Koefisien Korelasi Aktual-Prediksi
<i>XGBoost</i>	0,19	0,01
MLP	0,18	0,17

Dari *scatterplot* persentase kemiskinan menurut PODES 2018 dan hasil prediksi model MLP, terlihat model MLP memberikan nilai prediksi yang underestimate. Model MLP memberikan nilai prediksi kemiskinan pada kisaran angka 15-20 persen untuk semua wilayah desa di Kalimantan Barat (Gambar 4.8).



Gambar 4.8. Relasi persentase kemiskinan desa menurut PODES 2018 di Provinsi Kalimantan Barat dengan prediksi persentase desa di Provinsi Kalimantan Barat dengan model MLP disandingkan dengan garis $y=x$.


Jika ditelaah lebih lanjut, nilai prediksi ini tidak terlepas dari sebaran nilai NTL desa-desa di Provinsi Kalimantan Barat yang cenderung tidak bervariasi dengan rata-rata nilai yang cukup kecil (Tabel 4.4).

Tabel 4.5. Statistik Deskriptif Data Cahaya Malam Provinsi Kalimantan Barat


Kode Kab/Kota	Min	Max	Mean	Varians
6101	0.11	3.84	0.33	0.15
6102	0.00	0.41	0.19	0.01
6103	0.12	2.48	0.23	0.04
6104	0.01	2.02	0.47	0.13
6105	0.01	1.22	0.18	0.02
6106	0.09	9.94	0.34	0.82

6107	0.01	6.23	0.23	0.15
6108	-0.39	1.32	0.18	0.02
6109	0.03	0.44	0.18	0.01
6110	0.02	3.39	0.20	0.09
6111	0.07	0.52	0.19	0.01
6112	0.10	7.39	0.68	1.20
6171	4.18	56.42	13.89	121.10
6172	0.16	4.15	1.31	1.41

Perbandingan pola sebaran kemiskinan di Provinsi Kalimantan Barat menurut PODES 2018 dan hasil pemodelan MLP ditunjukkan oleh Gambar 4.9. Dengan nilai koefisien korelasi persentase kemiskinan aktual dan prediksi sebesar 0,17 (lih. Tabel 4.5), prediksi model MLP terbukti sama sekali tidak dapat menggambarkan pola kemiskinan menurut PODES 2018 di Provinsi Kalimantan Barat. Hal ini menunjukkan bahwa data NTL kurang sesuai untuk memodelkan tingkat kemiskinan di Provinsi Kalimantan Barat.



(a)



Gambar 4.9. Pola Sebaran Estimasi Kemiskinan Desa (a) Aktual dan (b) Prediksi MLP di Provinsi Kalimantan Barat

4.3. PEMBAHASAN

Berdasarkan pembahasan di atas, dapat kita lihat bahwa akurasi dan kinerja model bervariasi menurut provinsi. Hal ini dimungkinkan terjadi karena data NTL di setiap provinsi juga bervariasi. Dengan kata lain, karakteristik wilayah dapat berdampak pada akurasi dan kinerja model yang dihasilkan. Sebagai contoh, Papua dan Papua Barat adalah provinsi dengan akurasi prediksi yang lemah dan kinerja model yang kurang begitu bagus. Provinsi-provinsi ini adalah provinsi dengan nilai rata-rata NTL paling rendah. Dengan demikian, terdapat kemungkinan bahwa persentase kemiskinan tidak dapat diprediksi dengan baik pada daerah-daerah dengan rata-rata nilai NTL yang sangat rendah. Hal ini juga sebagaimana ditemukan oleh Yuan et.al (2019) pada studinya bahwa daerah dengan pasokan listrik yang tidak stabil akan membatasi penggunaan NTL untuk memprediksi aktivitas masyarakat di daerah tersebut.

Selain itu, salah satu hal yang perlu menjadi perhatian adalah pada kajian ini, NTL belum dipilah-pilah berdasarkan sumber cahaya, sehingga NTL tidak hanya mewakili cahaya yang bersumber pada pemukiman penduduk di malam hari, tetapi juga kemungkinan mencakup cahaya dari tempat non-pemukiman, seperti pabrik dan pembangkit listrik.

Selanjutnya, terdapat beberapa saran untuk kajian selanjutnya untuk mengeksplorasi potensi NTL untuk memprediksi kemiskinan. Pertama, selain menggunakan persentase kemiskinan secara langsung, variabel lainnya yang merupakan indikator kemiskinan juga patut untuk dicoba, misalnya menggunakan

Multidimensional Poverty Index (MPI), sebagaimana penelitian yang dilakukan oleh Puttanapong (2022). Selain itu, hal yang mungkin juga bisa dilakukan untuk meningkatkan akurasi dan kinerja model adalah dengan menambahkan variabel lain yang juga berkaitan dengan kemiskinan sehingga bagaimana kontribusi NTL dibandingkan variabel lainnya dalam prediksi kemiskinan bisa dievaluasi.

<https://www.bps.go.id>

V



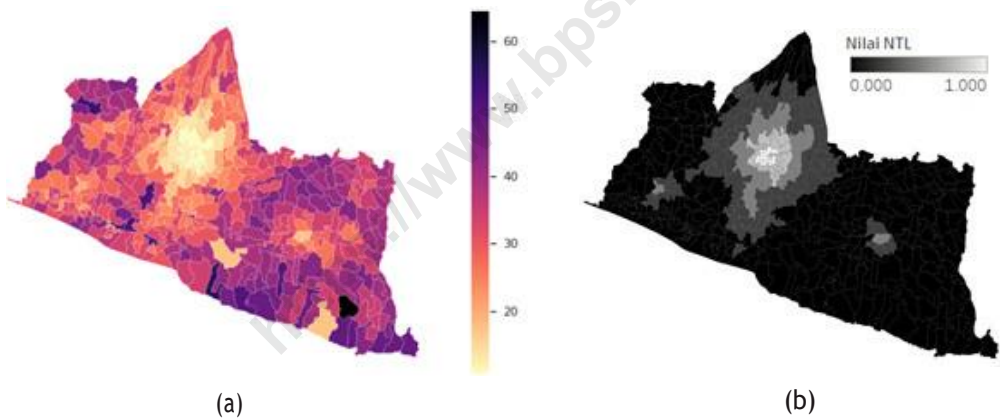


HASIL ESTIMASI KEMISKINAN DAN KETERKAITANNYA DENGAN KARAKTERISTIK WILAYAH BERDASARKAN DATA PODES 2018

Ana Lailatul Fitriyani, Dede Yoga Paramartha, Maulana Faris

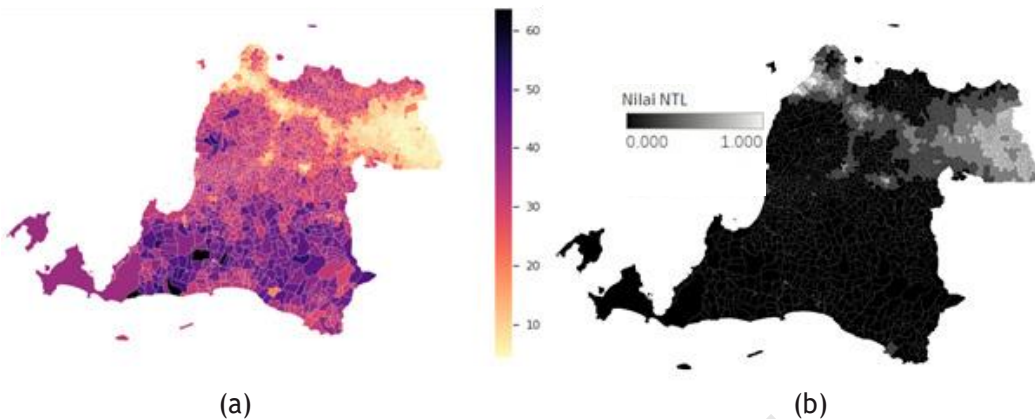
5.1. Gambaran Umum Hasil Estimasi Kemiskinan dan *Night Time Light* (NTL)

Fenomena kemiskinan dipandang sebagai ketidakmampuan seseorang dari sisi ekonomi untuk memenuhi kebutuhan dasar yang sering kali juga menyebabkan keterbatasan terhadap akses kebutuhan lainnya seperti akses pendidikan, kesehatan, air bersih, sanitasi, dan perumahan layak huni. Karakteristik rumah tangga miskin salah satunya dapat diamati melalui kondisi perumahan dan faktor yang menunjang perumahan seperti jenis lantai, dinding, atap rumah, penerangan, sumber air, jenis bahan bakar untuk memasak, sanitasi, dan sebagainya. Pada bab ini membahas mengenai keterkaitan hasil pemodelan kemiskinan dengan karakteristik wilayah berdasarkan data PODES 2018 di Provinsi D.I. Yogyakarta dan Provinsi Banten. Kedua provinsi tersebut dipilih sebagai contoh provinsi dengan hasil pemodelan kemiskinan yang cukup baik menurut nilai akurasi dan kinerja model seperti yang telah dibahas pada bab sebelumnya.



Gambar 5.1 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) nilai intensitas cahaya malam di Provinsi D.I. Yogyakarta tahun 2018

Berdasarkan hasil estimasi dan perbandingannya dengan data intensitas cahaya, didapatkan bahwa terdapat asosiasi yang berlawanan arah. Semakin tinggi intensitas cahaya lampu, persentase keluarga miskin di dalam suatu desa cenderung semakin rendah. Jika diamati secara sebaran di Provinsi DI Yogyakarta, kondisi tersebut tidak berlaku untuk seluruh desa, walaupun memang berlaku secara dominan untuk sebagian besar desa. Anomali banyak ditemukan pada wilayah selatan, dimana persentase keluarga miskin cenderung rendah, namun intensitas cahaya lampu malam cenderung redup.



Gambar 5.2 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) nilai intensitas cahaya malam di Provinsi Banten Tahun 2018

Kondisi di Provinsi Banten juga tidak berbeda jauh dengan kondisi pada Provinsi DI Yogyakarta terkait asosiasi antara intensitas cahaya lampu dan estimasi keluarga miskin pada tiap desa. Pola lain yang nampak dari pola cahaya dan kondisi kemiskinan dari Provinsi Banten adalah kemungkinan adanya efek spasial dari Provinsi DKI Jakarta. Hal ini dilihat dari intensitas lampu yang tinggi pada perbatasan Jakarta-Banten di Kota Tangerang dan Tangerang Selatan. Hal ini juga sejalan dengan estimasi keluarga miskin yang dihasilkan. Menurut Torres (2011), kemiskinan pada area rural memang memiliki keterkaitan secara spasial yang diakibatkan oleh akibat dari efek sosial-ekonomi daerah sekitarnya. Dengan demikian, dalam pengembangannya, model estimasi keluarga miskin dapat lebih mengembangkan pola spasial. Hal ini dikarenakan, secara tidak langsung, pola pada intensitas malam yang dapat memprediksi model kemiskinan dengan baik di Provinsi Banten juga kemungkinan memiliki efek spasial ini. Hal yang mungkin terjadi justru pola pada Kota Tangerang dan Tangerang Selatan justru akan lebih baik jika dimodelkan dengan Provinsi DKI Jakarta atau paling tidak memerhatikan efek spasial yang ada diantara keduanya.

5.2. Keterkaitan Kemiskinan dengan Karakteristik Wilayah Berdasarkan Data PODES 2018

5.2.1. Kemiskinan dan Kondisi Perumahan

Karakteristik rumah tangga miskin dapat diamati melalui kondisi perumahan dan faktor yang menunjang perumahan seperti jenis lantai, dinding, atap rumah, penerangan, sumber air, jenis bahan bakar untuk memasak, sanitasi, dan sebagainya. Pemukiman kumuh identik sebagai salah satu potret kemiskinan terutama di wilayah padat penduduk. Kemiskinan dapat dilihat dari rumah penduduk di lingkungan yang buruk, sempit dan padat, dan konstruksi yang kurang memenuhi persyaratan baku (Faturachman dan Molo, 1994).

Tingkat kepadatan bangunan yang tinggi pada kawasan pemukiman kumuh dapat mengindikasikan bahwa masyarakat tidak mampu membeli lahan untuk membangun

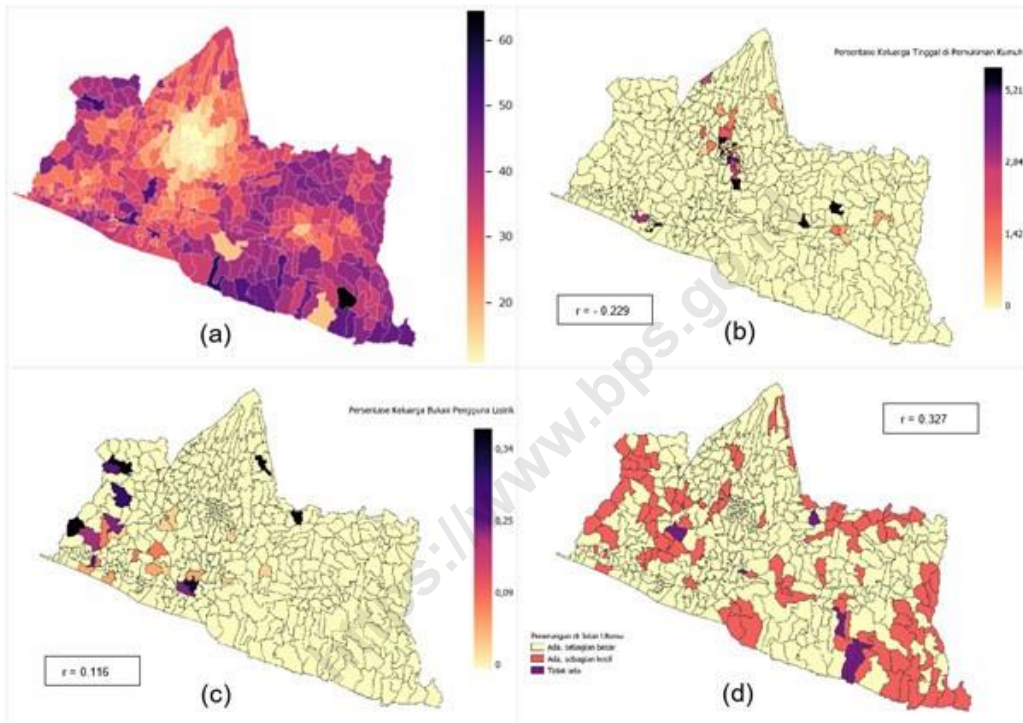
hunian yang memadai. Pemukiman kumuh biasanya ditandai dengan sanitasi lingkungan yang buruk, bangunan pemukiman padat dan sebagian besar bangunan tidak layak huni. Menurut Undang-Undang Nomor 1 Tahun 2011, permukiman kumuh adalah permukiman yang tidak layak huni karena ketidakteraturan bangunan, tingkat kepadatan bangunan yang tinggi, dan kualitas bangunan serta sarana dan prasarana yang tidak memenuhi syarat. Kondisi kumuhnya suatu kawasan pemukiman memiliki keterkaitan dengan jumlah penduduk miskin (Sintiawati, Wesnawa & Suditha, 2014). Pemukiman kumuh timbul akibat kondisi ekonomi masyarakat yang kurang memadai, khususnya masyarakat berpenghasilan rendah sehingga tidak mampu memiliki bangunan rumah yang layak (Andriana dan Manaf, 2017).

Selain faktor perumahan, kemiskinan rumah tangga juga dapat dilihat dari berbagai faktor penunjang perumahan seperti sumber penerangan, sumber air, dan bahan bakar utama yang digunakan untuk memasak. Rumah tangga miskin biasanya identik dengan wilayah dimana fasilitas penerangan dan air bersih kurang memadai (Faturachman dan Molo, 1994). Semakin buruk status ekonomi suatu keluarga menyebabkan keterbatasan terhadap akses kebutuhan lainnya, sehingga lebih memilih menggunakan sumber pemenuhan kebutuhan penunjang yang tidak banyak mengeluarkan biaya. Listrik sebagai sumber utama penerangan rumah tangga berhubungan positif dengan status ekonomi rumah tangga (Faturachman dan Molo, 1994). Semakin baik status ekonomi rumah tangga, semakin tinggi intensitas penggunaan listrik sebagai sumber penerangan maupun untuk kebutuhan yang lain. Di samping penggunaan listrik rumah tangga, sumber penerangan di jalan utama dapat menggambarkan ketersediaan fasilitas penerangan di suatu wilayah. Dari segi pengembangan wilayah, rumah tangga miskin identik dengan wilayah dimana ketersediaan fasilitas penerangan yang kurang memadai (Faturachman dan Molo, 1994).

Penggunaan sumber air untuk minum maupun mandi/cuci dan penggunaan bahan bakar utama untuk memasak juga dapat menggambarkan tingkat pengeluaran dan kemampuan ekonomi rumah tangga. Penggunaan sumber air minum dan sumber air untuk mandi/cuci yang tidak membutuhkan banyak biaya maka semakin kecil pengeluaran rumah tangga untuk memenuhi keperluan sumber air. Rumah tangga miskin tidak mampu membeli air minum yang sehat sehingga lebih mengutamakan sumber air yang lebih murah (Faturachman dan Molo, 1994).

Hasil pemodelan kemiskinan Provinsi D.I. Yogyakarta menunjukkan wilayah Kota Yogyakarta memiliki tingkat kemiskinan paling rendah dibandingkan wilayah kabupaten yang lain (Gambar 5.3.a). Namun disisi lain berdasarkan data PODES 2018, sebaran keluarga yang tinggal di pemukiman kumuh juga banyak terpusat di wilayah perkotaan tersebut (Gambar 5.3.b). Tingkat kepadatan penduduk yang lebih tinggi di perkotaan dan pertumbuhan populasi yang pesat akibat pengaruh urbanisasi merupakan salah satu penyebab kekumuhan (Andriana dan Manaf, 2017; Dalilah dan Ridwana, 2019). Pertumbuhan penduduk yang cepat menyebabkan semakin besarnya kebutuhan ruang untuk tempat tinggal sehingga mengakibatkan berkembangnya pemukiman tidak terkontrol, terutama pemukiman kumuh yang dapat mengakibatkan menurunnya kualitas

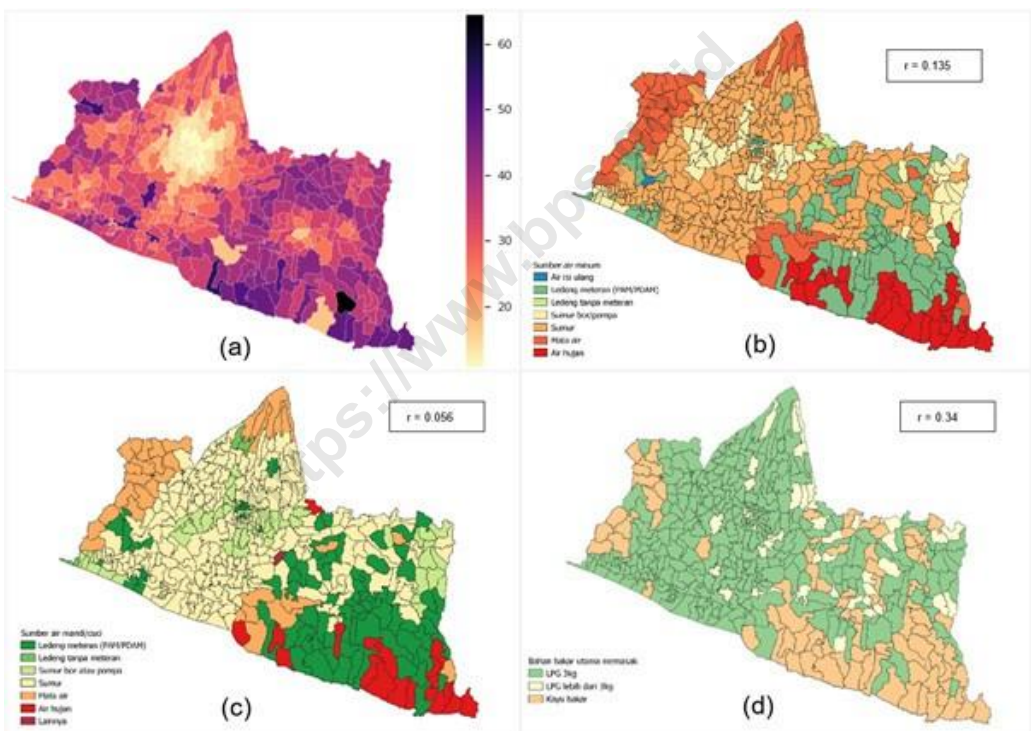
pemukiman (Ekatarji, Yunus dan Rahardjo, 2016). Wilayah perkotaan memiliki tingkat kepadatan penduduk yang lebih tinggi, sehingga mengakibatkan timbulnya berbagai masalah dalam penataan ruang. Banyak masyarakat pedesaan migrasi ke perkotaan untuk mendapatkan kehidupan yang lebih baik, selain itu pembangunan yang terus dilakukan menjadikan ketimpangan antara desa dan kota (Andriana dan Manaf, 2017).



Gambar 5.3 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) persentase keluarga yang tinggal di pemukiman kumuh, (c) persentase keluarga bukan pengguna listrik, (d) penerangan di jalan utama desa/kelurahan Provinsi D.I. Yogyakarta berdasarkan PODES 2018

Sementara jika dilihat sebaran desa berdasarkan persentase rumah tangga bukan pengguna listrik, Kabupaten Kulon Progo merupakan wilayah yang paling banyak terdapat desa dengan persentase rumah tangga bukan pengguna listrik. Hal tersebut sejalan dengan hasil pemodelan kemiskinan pada Gambar 5.3.a yang menunjukkan wilayah tersebut secara umum memiliki tingkat kemiskinan yang cukup tinggi. Selain itu, berdasarkan ketersediaan penerangan di jalan utama di wilayah Kabupaten Kulon Progo juga masih banyak desa yang hanya memiliki sebagian kecil penerangan jalan utama. Hal tersebut sejalan dengan tingkat cahaya citra malam di wilayah tersebut yang cenderung rendah. Di sisi lain, hasil pemodelan kemiskinan menunjukkan wilayah Kabupaten Gunungkidul memiliki persentase kemiskinan yang relatif tinggi, namun pada wilayah tersebut cenderung memiliki persentase keluarga bukan pengguna listrik rendah

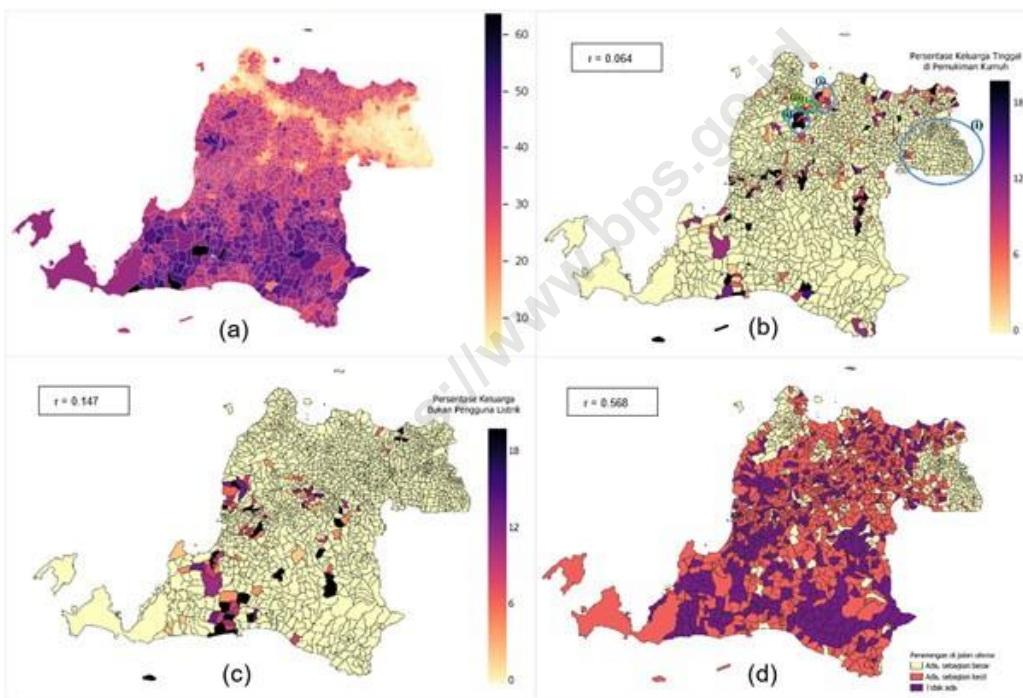
atau sebagian besar keluarga telah menggunakan listrik sebagai sumber penerangan. Persentase keluarga yang tidak menggunakan listrik di wilayah Kabupaten Gunungkidul relatif rendah namun tingkat cahaya malam hari di wilayah tersebut cenderung rendah. Hal tersebut kemungkinan juga dipengaruhi oleh faktor lain seperti faktor penerangan jalan. Berdasarkan ketersediaan sumber penerangan jalan utama di Kabupaten Gunungkidul masih banyak desa yang hanya memiliki sebagian kecil penerangan jalan utama atau bahkan di beberapa desa tidak memiliki sumber penerangan jalan utama. Selain itu, tingkat pencahayaan malam hari yang rendah juga dapat dipengaruhi oleh intensitas penggunaan listrik itu sendiri, sehingga meski sebagian besar keluarga di wilayah tersebut telah menggunakan listrik kemungkinan intensitas penggunaannya cenderung rendah dibandingkan wilayah perkotaan.



Gambar 5.4 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) sumber air untuk minum sebagian besar keluarga, (c) sumber air untuk mandi/cuci sebagian besar keluarga, (d) bahan bakar untuk memasak sebagian besar keluarga di Provinsi D.I. Yogyakarta berdasarkan PODES 2018

Sebagian besar sumber air minum dan mandi/cuci di wilayah Kabupaten Kulonprogo bersumber dari mata air dan sumur, sedangkan di wilayah Gunung Kidul meskipun banyak desa yang sumber utama air minum dan air mandi/cuci menggunakan air ledeng namun masih banyak juga desa yang mengandalkan air hujan sebagai sumber air utama untuk minum dan mandi/cuci. Berbeda dengan di desa, di kota penggunaan air minum sangat terkait dengan kemiskinan. Di pusat Kota Yogyakarta, penggunaan

sumber air untuk minum sebagian besar menggunakan air isi ulang dan sebagian besar sumber air untuk mandi/cuci berasal dari ledeng meteran/PAM/PDAM. Hal tersebut sejalan dengan hasil pemodelan kemiskinan di Kota Yogyakarta yang diprediksi memiliki tingkat kemiskinan yang relatif rendah. Penggunaan bahan bakar utama untuk memasak juga dapat menggambarkan tingkat pengeluaran dan kemampuan ekonomi suatu rumah tangga. Hasil perbandingan sebaran penggunaan jenis bahan bakar utama yang digunakan untuk memasak menunjukkan hasil yang sejalan dengan hasil pemodelan kemiskinan cahaya citra malam. Wilayah yang diprediksi memiliki tingkat kemiskinan relatif tinggi sebagian besar keluarga di desa tersebut menggunakan kayu bakar sebagai bahan bakar utama untuk memasak.

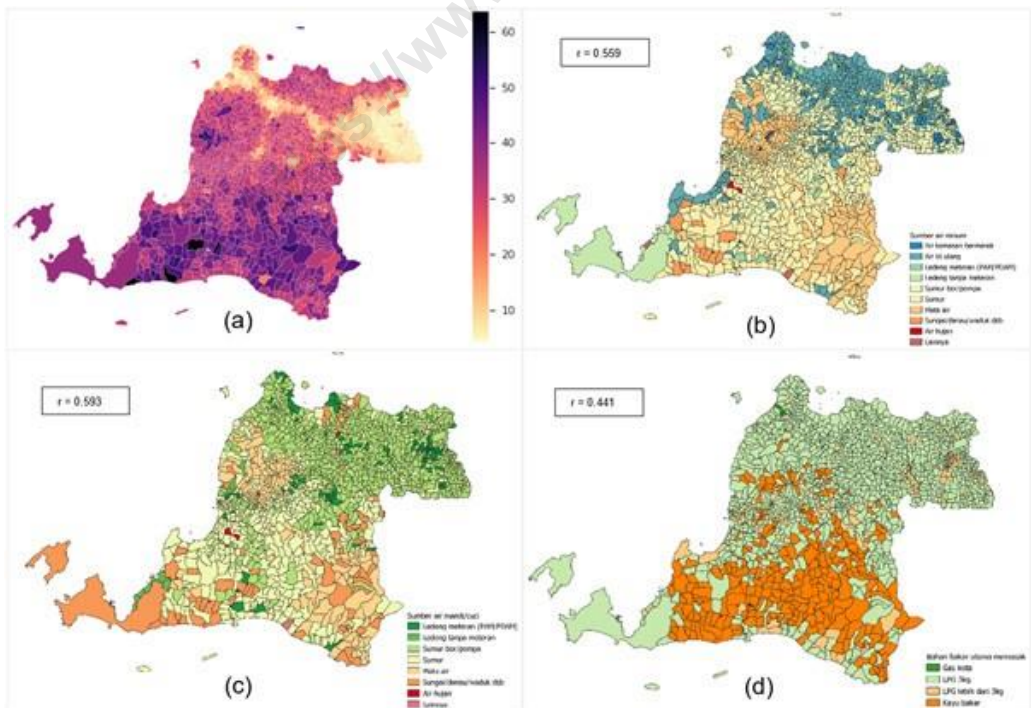


Gambar 5.5 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) persentase keluarga yang tinggal di pemukiman kumuh, (c) persentase keluarga bukan pengguna listrik, (d) penerangan di jalan utama desa/kelurahan Provinsi Banten berdasarkan PODES 2018

Sama halnya dengan hasil prediksi kemiskinan sebelumnya, pola sebaran kemiskinan di Provinsi Banten juga cenderung memiliki tingkat kemiskinan yang rendah pada pusat-pusat wilayah perkotaan seperti Kota Tangerang, Kota Serang, dan Kota Cilegon. Perbandingan pola sebaran keluarga miskin hasil pemodelan kemiskinan di Provinsi Banten dengan sebaran keluarga yang tinggal di pemukiman kumuh berdasarkan data PODES 2018 menunjukkan terdapat hasil yang bersesuaian pada beberapa wilayah seperti pada wilayah yang ditunjukkan oleh kode (i) pada Gambar 5.5.b. Wilayah berkode (i) merupakan contoh wilayah dengan prediksi tingkat kemiskinan dan keberadaan

keluarga pemukiman kumuh yang sejalan. Disisi lain, terdapat juga hasil perbandingan pola prediksi kemiskinan dan sebaran keluarga pemukiman kumuh yang tidak sejalan seperti yang ditunjukkan pada wilayah berkode (ii). Wilayah berkode (ii) merupakan wilayah perkotaan yang diprediksi memiliki tingkat kemiskinan yang rendah berdasarkan model cahaya citra malam, namun ternyata pada wilayah tersebut memiliki persentase keluarga yang tinggal di pemukiman kumuh cukup tinggi.

Pola sebaran keluarga bukan pengguna listrik maupun ketersediaan penerangan jalan utama di Provinsi Banten menunjukkan hasil yang bersesuaian khususnya pada wilayah yang dideteksi sebagai wilayah dengan tingkat kemiskinan rendah menurut hasil pemodelan kemiskinan dengan cahaya citra malam. Seperti yang terlihat pada kawasan pusat-pusat Kota Tangerang, Kota Serang dan Kota Cilegon yang memiliki persentase keluarga bukan pengguna listrik rendah dan sebagian besar wilayah telah memiliki penerangan jalan utama. Hasil tersebut sejalan dengan hasil prediksi model kemiskinan yang menunjukkan ketiga wilayah tersebut memiliki persentase tingkat kemiskinan yang rendah. Sedangkan pada wilayah yang diprediksi memiliki tingkat kemiskinan relatif tinggi pada beberapa desa masih terdapat keluarga yang tidak menggunakan listrik dengan persentase yang cukup tinggi dan banyak desa yang hanya memiliki sebagian kecil maupun tidak memiliki sumber penerangan jalan utama.



Gambar 5.6 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) sumber air untuk minum sebagian besar keluarga, (c) sumber air untuk mandi/cuci sebagian besar keluarga, (d) bahan bakar untuk memasak sebagian besar keluarga di Provinsi Banten berdasarkan PODES 2018

Selanjutnya hasil perbandingan pola sebaran penggunaan sumber air dengan sebaran prediksi kemiskinan di Provinsi Banten menunjukkan bahwa pada wilayah yang diprediksi memiliki tingkat kemiskinan relatif rendah memiliki kecenderungan penggunaan sumber air minum bersumber dari air kemasan bermerek dan air isi ulang dan penggunaan sumber air untuk mandi/cuci sebagian besar bersumber dari sumur bor/pompa. Pada wilayah pusat Kota Tangerang nampak sebagian besar penggunaan sumber air untuk mandi/cuci berasal dari ledeng meteran (PAM/PDAM). Sementara pada wilayah-wilayah yang diprediksi memiliki tingkat kemiskinan relatif tinggi terdapat kecenderungan penggunaan sumber air untuk minum berasal dari sumur dan mata air, serta terdapat sebagian kecil desa yang sumber air utama untuk minum berasal dari air hujan dan air sungai/danau/waduk dan sebagainya. Sedangkan penggunaan sumber air untuk mandi/cuci pada wilayah yang diprediksi memiliki tingkat kemiskinan relatif tinggi tampak lebih beragam yaitu sumur, mata air, serta air sungai/danau/waduk dan sebagainya. Selain itu, sebaran penggunaan jenis bahan bakar utama yang digunakan untuk memasak menunjukkan hasil yang sejalan dengan prediksi kemiskinan cahaya citra malam. Wilayah yang diprediksi memiliki tingkat kemiskinan relatif tinggi sebagian besar keluarga di desa tersebut menggunakan kayu bakar sebagai bahan bakar utama untuk memasak.

Di perkotaan, penduduk miskin identik dengan penduduk yang tinggal di pemukiman kumuh (Andriana dan Manaf, 2017). Berdasarkan hasil perbandingan pada kedua provinsi tersebut dapat disimpulkan bahwa fenomena kemiskinan perkotaan yang berasal dari pemukiman kumuh belum dapat sepenuhnya ditangkap hanya menggunakan model prediksi kemiskinan data cahaya citra malam. Sehingga diperlukan kajian lebih lanjut dan penambahan variabel-variabel lain untuk menangkap kemiskinan perkotaan terutama di pemukiman-pemukiman kumuh.


5.2.2. Kemiskinan dan Upaya Pendidikan

Informasi dan pengetahuan sekarang menjadi aset penting dalam ekonomi global. Negara-negara di dunia saat ini sedang menciptakan strategi untuk memastikan bahwa informasi dan pengetahuan digunakan secara efektif, dibagikan, dan dapat diakses. Sebagian besar didorong oleh keinginan untuk tidak kalah atau tertinggal dalam proses kemajuan TIK. Dalam pidatonya pada tahun 2000, Tony Blair berbicara tentang transformasi ekonomi melalui teknologi informasi, dengan mengatakan bahwa “dalam lingkungan baru ini komoditas terpenting suatu bangsa adalah informasi dan pengetahuan” (Blair 2000).

Menurut studi Oranga (2020), data menunjukkan bahwa peningkatan akses ke pendidikan dapat berkontribusi pada pertumbuhan ekonomi dan pengentasan kemiskinan. Dengan demikian, keterampilan dasar yang diperoleh seperti membaca, menulis, dan berhitung memiliki efek positif pada pendapatan penduduk yang terpinggirkan dan tingkat pengembalian ekonomi. Hal ini juga yang memicu adanya


pemberantasan buta aksara dan juga program pendidikan anak usia dini dalam menunjang kemampuan dasar di dunia pendidikan.

Berdasarkan survei pada PODES 2018, terdapat instrumen yang menggali mengenai peningkatan kapabilitas dari sisi pendidikan baik untuk anak-anak hingga lanjut usia. Terdapat variabel ada atau tidaknya pengentasan buta aksara dan paket A/B/C. Selain itu, ada juga variabel mengenai ada tidaknya fasilitas di desa yang menunjang pertumbuhan anak melalui taman bermain dan pelatihan anak usia dini. Beberapa variabel ini kemudian dianalisis ke dalam dua dimensi yaitu upaya penanggulangan pendidikan fasilitas tumbuh kembang anak.



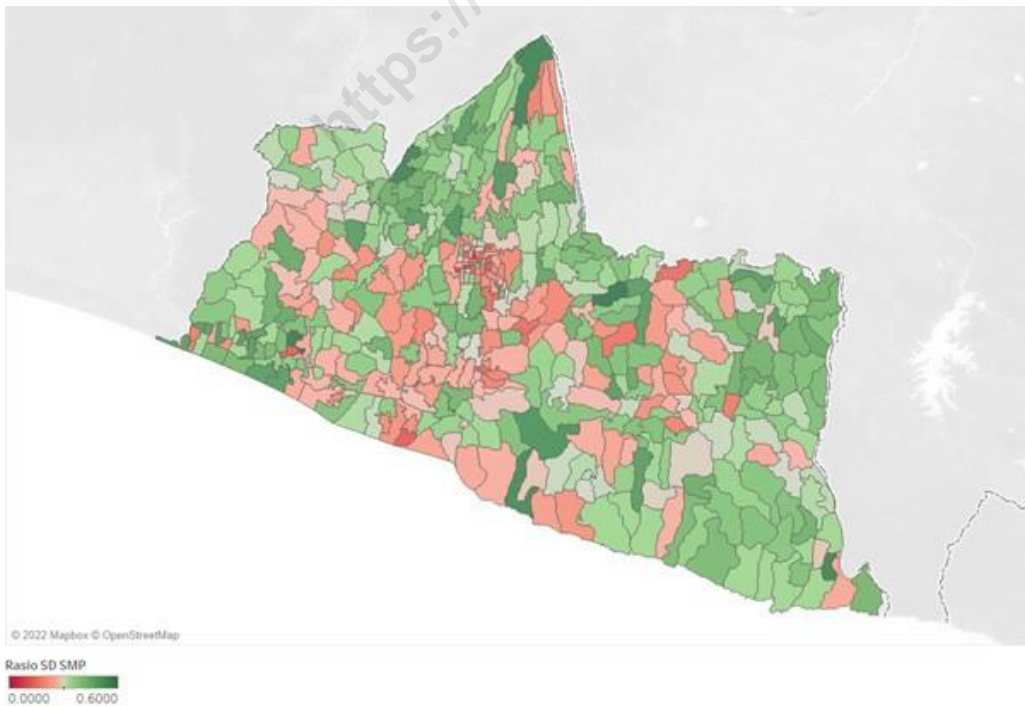
Gambar 5.7 Rata-rata intensitas cahaya dan persentase keluarga miskin berdasarkan kepemilikan desa terhadap (a) Program pengentasan buta aksara dan (b) program paket A/B/C di Provinsi D.I Yogyakarta Berdasarkan Data PODES 2018

Berdasarkan data penanggulangan pendidikan di Jogja, desa dengan adanya fasilitas ini cenderung memiliki intensitas cahaya yang rendah sekaligus dengan estimasi keluarga miskin yang tinggi. Hal ini tentu berasosiasi terbalik dengan efek pendidikan kepada kemiskinan. Jika melihat struktur penduduk Provinsi DI Yogyakarta, menurut data BPS, mayoritas penduduk berada pada usia produktif (15-64 tahun). Dari sisi pendidikan, Provinsi DIY memiliki rata-rata lama sekolah dan harapan lama sekolah masing-masing sebesar 9,64 dan 15,64 tahun. Kondisi ini menunjukkan bahwa kemungkinan penanggulangan pendidikan di Provinsi DIY akan lebih banyak berada pada daerah yang memang membutuhkan, dimana daerah tersebut merupakan desa dengan tingkat pendidikan yang rendah.



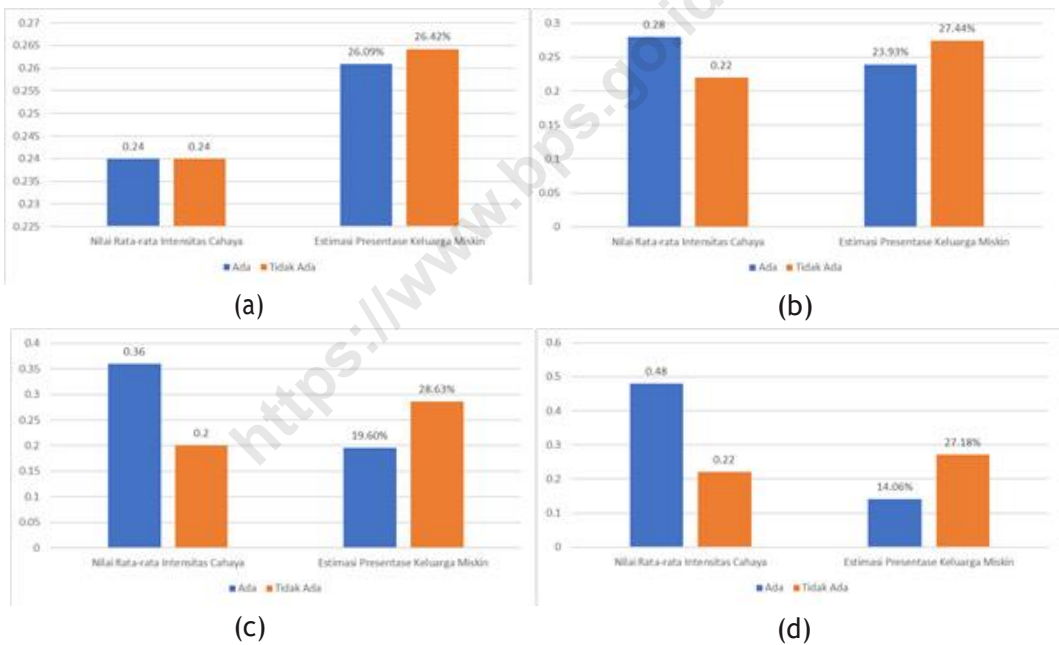
Gambar 5.8 Rata-rata intensitas cahaya dan persentase keluarga miskin berdasarkan kepemilikan desa terhadap (a) fasilitas penitipan anak dan (b) fasilitas tempat temu sebaya di Provinsi D.I Yogyakarta Berdasarkan Data PODES 2018

Kondisi yang terbalik terjadi pada dimensi terkait dengan fasilitas pendidikan di Provinsi DIY. Daerah dengan fasilitas tumbuh kembang anak memiliki intensitas cahaya malam yang tinggi dan juga persentase keluarga miskin yang cenderung lebih rendah. Hal ini sejalan tentang asosiasi antara kemiskinan dan juga pendidikan. Daerah dengan tingkat pengembangan pendidikan yang cenderung lebih baik akan memiliki kualitas lingkungan yang cenderung lebih baik dan juga kondisi kemiskinan yang lebih rendah. Dengan adanya indikasi ini, maka dapat diberikan saran mengenai pengembangan kualitas pendidikan pada daerah tertinggal pada desa-desa di Provinsi DIY.



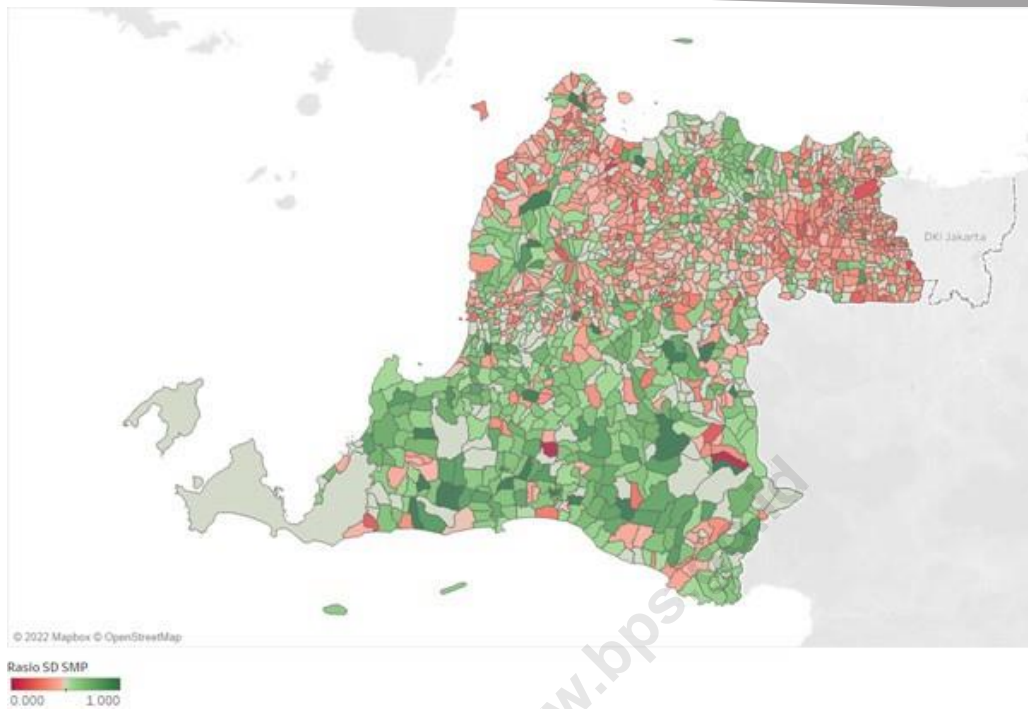
Gambar 5.9 Rasio Jumlah SD-SMP Terhadap Seluruh Sarana Pendidikan di Provinsi DI Yogyakarta

Pada PODES 2018, juga terdapat data terkait dengan jumlah sarana pendidikan seperti SD hingga perguruan tinggi. Dengan berpatokan pada program pemerintah terkait wajib belajar 9 tahun, dapat dianalisis mengenai seberapa besar rasio dari sarana pendidikan SD-SMP jika dibandingkan dengan seluruh sarana pendidikan yang ada di sebuah desa. Semakin tinggi nilai yang didapat, maka daerah tersebut dikatakan sebagai daerah dengan opsi pendidikan yang rendah karena mendekati kondisi pendidikan minimum (wajib belajar 9 tahun). Pada Provinsi DI Yogyakarta, terlihat bahwa daerah dengan kemiskinan yang rendah justru memiliki rasio yang rendah. Jika melihat fenomena ini, maka dapat dikatakan bahwa opsi pendidikan lebih tinggi memang berasosiasi pada daerah yang memiliki kemiskinan yang rendah.



Gambar 5.10 Rata-rata intensitas cahaya dan persentase keluarga miskin berdasarkan kepemilikan desa terhadap (a) Program pengentasan buta aksara, (b) program paket A/B/C, (c) fasilitas penitipan anak, dan (d) fasilitas tempat temu sebaya di Provinsi Banten Berdasarkan Data PODES 2018

Berbeda dengan kondisi pada Provinsi DIY, Provinsi Banten memiliki kondisi yang searah antara variabel penanggulangan kemiskinan dan juga fasilitas tumbuh kembang anak. Desa dengan penanggulangan dan fasilitas tumbuh kembang anak memiliki intensitas cahaya yang cenderung lebih baik dan juga estimasi kemiskinan keluarga yang lebih rendah dibandingkan dengan daerah yang tidak memiliki. Dengan kondisi ini, maka dapat dikatakan bahkan pada provinsi Banten, perlu adanya pemerataan yang lebih baik untuk pendidikan karena asosiasinya kepada kemiskinan cukup terlihat.



Gambar 5.11 Rasio Jumlah SD-SMP Terhadap Seluruh Sarana Pendidikan di Provinsi Banten

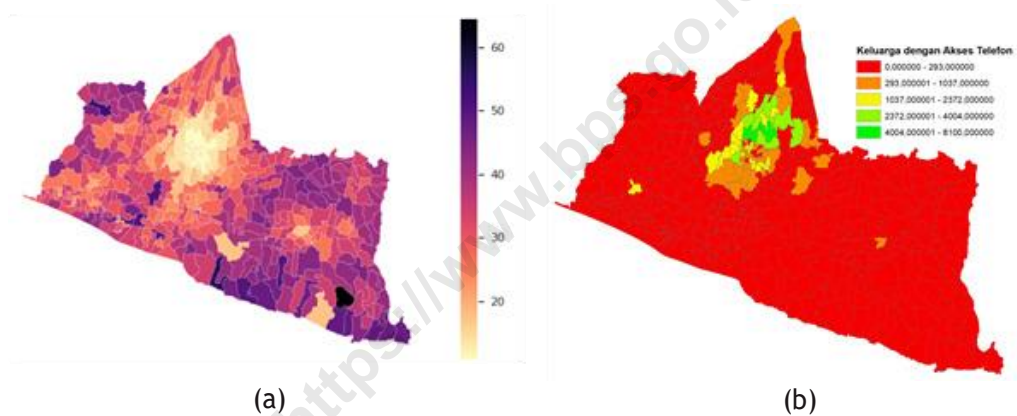
Pada Provinsi Banten, terkait dengan rasio SD-SMP terhadap seluruh sarana pendidikan, hal yang serupa terjadi seperti pada Provinsi DI Yogyakarta. Daerah yang memiliki tingkat kemiskinan rendah, juga memiliki rasio SD-SMP yang rendah. Dengan demikian, pada Provinsi Banten juga memiliki pola kemiskinan yang rendah pada daerah-daerah yang memiliki potensi perluasan pendidikan yang lebih tinggi.

5.2.3.. Kemiskinan dan Aksesibilitas Teknologi Informasi

Tahun 2020, pandemi menyerang Indonesia dan dunia, sekaligus memunculkan pemanfaatan yang masif dari teknologi. Teknologi digital tidak hanya memungkinkan masyarakat untuk mengadopsi cara yang lebih efisien dan lebih aman untuk mengendalikan penyebaran Virus Corona Baru, tetapi juga membantu keluarga dan komunitas yang rentan untuk mengurangi ancaman kemiskinan yang disebabkan oleh epidemi (WSIS Forum 2022). Misalnya, terminal seluler dapat memperoleh akses tepat waktu dan nyaman ke informasi penting seperti vaksinasi, kebutuhan sehari-hari, tunjangan bantuan pemerintah, harga transaksi pasar, dan sebagainya. Jaringan komunikasi broadband dan nirkabel yang andal dan aman juga memungkinkan pelaksanaan pendidikan jarak jauh yang efektif dan memberikan kesempatan yang aman bagi anak di bawah umur yang rentan untuk menerima pendidikan.

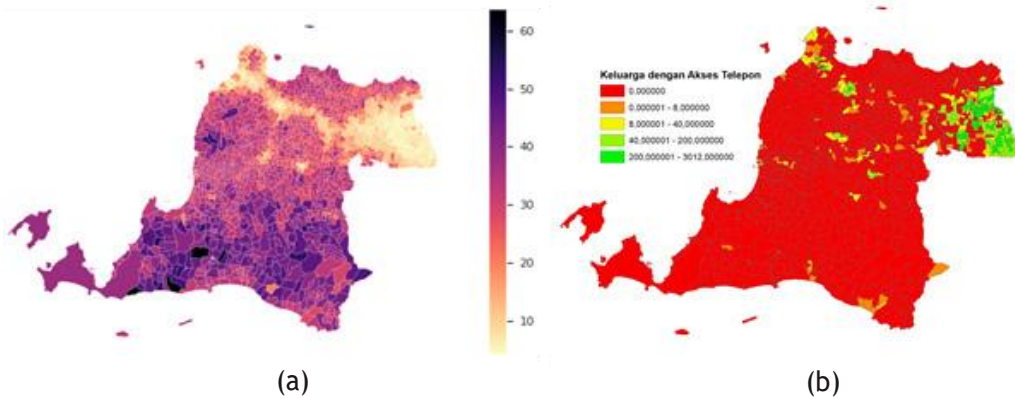
Walaupun dengan banyaknya manfaat langsung TIK, seringkali tidak jelas apakah mereka lebih efisien atau hemat biaya daripada cara tradisional. Sering juga tidak jelas apakah orang miskin memiliki keuangan dan pendidikan yang dapat dimanfaatkan untuk memanfaatkan peluang ekonomi yang disediakan oleh TIK baru (Quibria, 2001). Namun, hal yang jelas dari aspek teknologi adalah cerminan dari suatu daerah memiliki kemungkinan perluasan pilihan yang tinggi dalam upayanya untuk menjauh dari kondisi kemiskinan.

Dengan pemanfaatan data podes, dilakukan perbandingan apakah daerah dengan akses teknologi yang tinggi akan memiliki potensi kemiskinan yang rendah. Data yang digunakan sebagai perbandingan adalah data mengenai kepemilikan akses telepon dari suatu keluarga. Dengan akses ini tentu akan lebih banyak hal yang kemudian dapat dilakukan seperti pemberdayaan internet dan media komunikasi lain.




Gambar 5.12 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) keluarga dengan akses telepon di Provinsi D.I. Yogyakarta berdasarkan PODES 2018

Pada Provinsi DIY, terlihat bahwa daerah yang memiliki akses telepon yang tinggi akan memiliki kecenderungan kemiskinan keluarga yang lebih rendah. Namun, jika dicermati lebih dalam, hal ini cenderung berlaku pada pusat Provinsi DIY saja dan tidak pada daerah-daerah lain. Hal ini memunculkan asumsi awal mengenai fasilitas yang ada masih kurang untuk memengaruhi cakupan daerah ke area yang lebih besar. Selain itu, jika melihat asosiasi antara kepemilikan telepon dan keluarga miskin, tentu akan lebih mengacu kepada hubungan akibat, dimana keluarga yang tidak miskin yang akan dapat memiliki akses tersebut, terlepas dari sarana yang ada. Hal ini akan bersesuaian dengan prinsip permintaan yang akan memacu industri atau produksi.



Gambar 5.13 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) keluarga dengan akses telepon di Provinsi Banten berdasarkan PODES 2018

Hal yang serupa juga terjadi pada provinsi Banten. Daerah Tangerang dan juga Tangerang Selatan yang berdekatan dengan Provinsi Jakarta memiliki akses telepon yang lebih tinggi. Hal ini berasosiasi dengan rendahnya tingkat keluarga miskin pada daerah dengan akses telepon yang tinggi. Kondisi ini juga berasosiasi dengan kondisi intensitas cahaya lampu berdasarkan citra satelit. Hal ini menunjukkan adanya asosiasi antara kemiskinan dengan akses terhadap teknologi. Namun perlu adanya kajian yang lebih mendalam mengenai arah hubungan antara kedua dimensi tersebut. Teknologi dapat didapatkan dari keluarga dengan tingkat ekonomi yang baik, namun di sisi lain teknologi juga dapat memberikan akses dalam perluasan pilihan dalam upaya keluar dari jeratan kemiskinan.



Gambar 5.14 Persebaran Jumlah BTS di Provinsi D.I Yogyakarta dan Banten berdasarkan PODES 2018

Jika membicarakan mengenai akses informasi yang memiliki asosiasi dengan kemiskinan, penting juga untuk membahas upaya penyiapan fasilitas dalam mendukung permintaan terhadap kebutuhan akses teknologi. Salah satu indikator podes yang dapat menjadi acuan adalah BTS yang telah dibangun. Jika melihat sebaran BTS, terlihat bahwa sudah adanya distribusi BTS yang terbangun cukup baik di Provinsi DIY maupun Banten. Dengan baiknya kondisi ini, maka upaya perluasan akses dalam pengentasan kemiskinan bukan hal yang sulit untuk diwujudkan. Akses BTS ini akan memudahkan akses komunikasi dan juga informasi melalui media seperti internet.

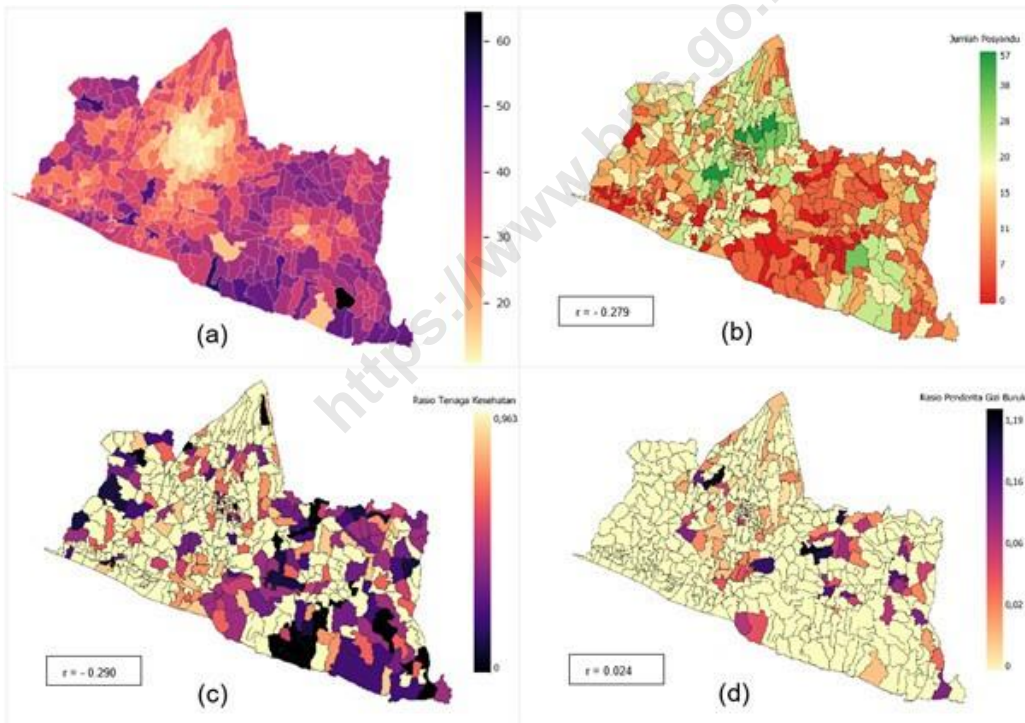
5.2.4. Kemiskinan dan Sarana Kesehatan

Kesehatan sekarang menjadi agenda internasional yang lebih tinggi daripada sebelumnya, dan kepedulian terhadap kesehatan masyarakat miskin menjadi isu sentral dalam pembangunan. Tujuan dari SDGs kini dari sisi kesehatan meliputi: mengurangi kematian anak, kematian ibu, dan penyebaran HIV/AIDS, malaria dan TBC. Bangsa-bangsa di dunia telah sepakat bahwa menikmati standar kesehatan tertinggi yang dapat dicapai adalah salah satu hak dasar setiap manusia, tanpa membedakan ras, agama, keyakinan politik, kondisi ekonomi atau sosial. Di luar nilai intrinsiknya bagi individu, kesehatan juga merupakan pusat pembangunan manusia secara keseluruhan dan pengurangan kemiskinan (OECD, 2003).

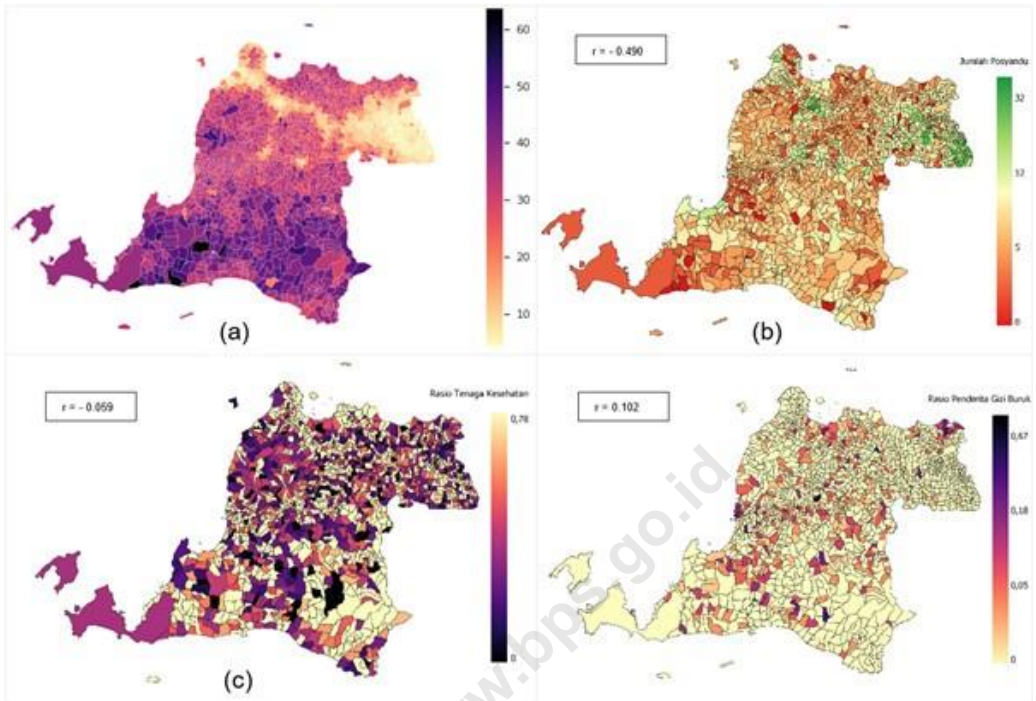
Penduduk miskin rentan terhadap tingkat kesehatan yang lebih buruk dan angka harapan hidup lebih rendah. Mereka memiliki angka kematian anak dan ibu yang lebih tinggi dari rata-rata, tingkat penyakit yang lebih tinggi, dan akses yang lebih terbatas kepada perawatan kesehatan dan perlindungan sosial. Ketidaksetaraan gender juga semakin merugikan kesehatan perempuan dan anak perempuan miskin. Khususnya bagi masyarakat miskin, kesehatan juga merupakan aset ekonomi yang sangat penting. Ketika orang miskin menjadi sakit atau terluka, seluruh rumah tangga dapat terjebak dalam spiral kehilangan pendapatan dan biaya perawatan kesehatan yang tinggi. Investasi di bidang kesehatan semakin diakui sebagai sarana penting pembangunan ekonomi dan prasyarat bagi negara-negara berkembang khususnya bagi masyarakat miskin untuk keluar dari lingkaran kemiskinan. Kesehatan yang baik berkontribusi pada pembangunan dalam beberapa cara: meningkatkan produktivitas tenaga kerja, pencapaian pendidikan dan investasi, dan memfasilitasi transisi demografis.

Dalam melihat aspek kesehatan diantaranya dapat didekati dengan adanya akses kepada sarana kesehatan, keberadaan tenaga kesehatan dan penduduk penderita gizi buruk. Sarana kesehatan yang tersedia di desa dapat berupa posyandu. Posyandu adalah wadah pemeliharaan kesehatan yang dilakukan dari, oleh dan untuk masyarakat yang dibimbing petugas terkait (Departemen Kesehatan RI. 2006). Berdasarkan perbandingan antara ketersediaan fasilitas kesehatan berupa posyandu dengan kondisi kemiskinan keluarga di Provinsi D.I. Yogyakarta, secara umum daerah-daerah yang memiliki akses kesehatan rendah adalah daerah memiliki tingkat kemiskinan keluarga tinggi. Sementara

berdasarkan rasio tenaga kesehatan terhadap jumlah penduduk, diketahui bahwa daerah yang memiliki tingkat kemiskinan rendah umumnya memiliki rasio tenaga kesehatan yang lebih tinggi. Fenomena kemiskinan juga tidak terlepas dari terbatasnya kemampuan seseorang untuk memenuhi kebutuhan dasar makanan sehingga sangat rentan untuk menderita gizi buruk. Perbandingan antara sebaran rasio penderita gizi buruk dengan hasil pemodelan kemiskinan desa di Provinsi D.I. Yogyakarta menunjukkan tidak semua daerah yang memiliki kemiskinan keluarga yang tinggi merupakan daerah yang juga memiliki rasio penderita gizi buruk tinggi. Sementara pada daerah dengan tingkat kemiskinan rendah, rasio penderita gizi buruk juga masih ditemui di beberapa daerah. Rasio gizi buruk yang tinggi kemungkinan juga dipengaruhi oleh faktor lain di luar faktor kemiskinan seperti pendidikan, akses layanan kesehatan, sanitasi, kondisi lingkungan, dan sebagainya.

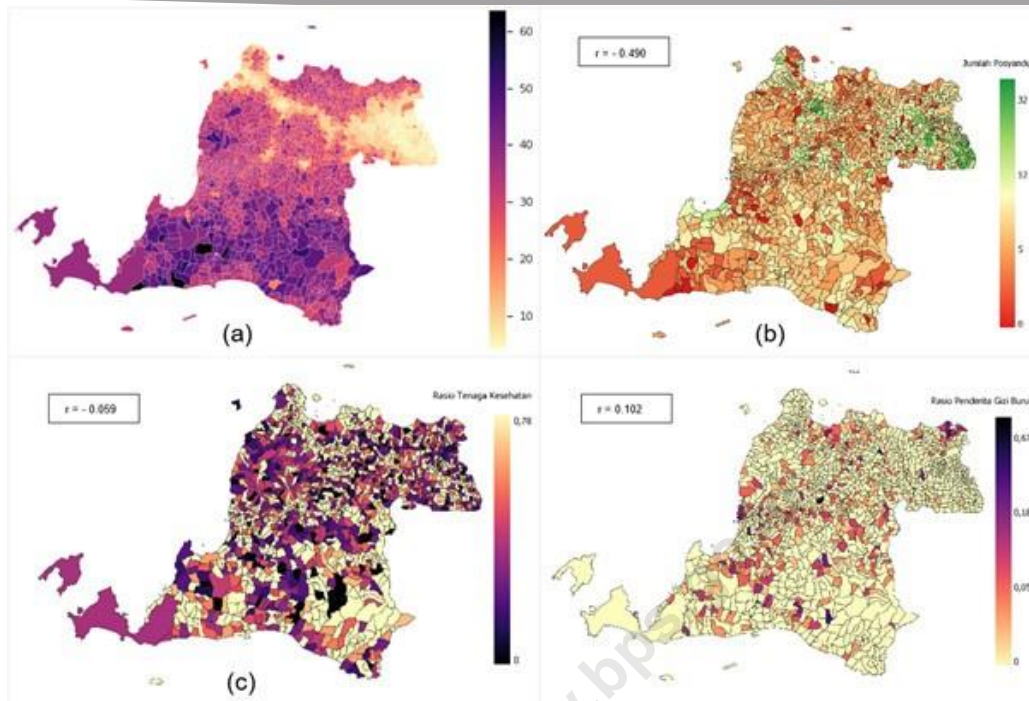


Gambar 5.15 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) sebaran jumlah posyandu tiap desa, (c) rasio tenaga kesehatan per seratus penduduk, (d) rasio penderita gizi buruk per seratus penduduk di Provinsi D.I. Yogyakarta berdasarkan PODES 2018



Gambar 5.16 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) sebaran jumlah posyandu tiap desa, (c) rasio tenaga kesehatan per seratus penduduk, (d) rasio penderita gizi buruk per seratus penduduk di Provinsi Banten berdasarkan PODES 2018

Hasil perbandingan antara ketersediaan fasilitas kesehatan berupa posyandu dengan kondisi kemiskinan keluarga di Provinsi Banten juga menunjukkan hasil yang sejalan. Daerah-daerah yang memiliki tingkat kemiskinan keluarga yang tinggi adalah daerah yang juga memiliki akses kesehatan yang rendah. Daerah dengan fasilitas kesehatan yang tinggi umumnya berada pada daerah sentral dan juga daerah yang memiliki perkembangan yang tinggi. Hal ini tentu bersebrangan dengan target SDGs mengenai pemerataan akses kesehatan agar semua kalangan tetap mendapatkan fasilitas kesehatan yang prima. Sedangkan berdasarkan sebaran rasio tenaga kesehatan dan rasio penderita gizi buruk, daerah yang memiliki tingkat kemiskinan rendah umumnya memiliki rasio tenaga kesehatan yang tinggi dan rasio penderita gizi buruk yang rendah. Sedangkan pada daerah dengan tingkat kemiskinan tinggi, sebaran rasio tenaga kesehatan dan rasio penderita gizi buruk cenderung beragam.



Gambar 5.17 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) sebaran jumlah posyandu tiap desa, (c) rasio tenaga kesehatan per seratus penduduk, (d) rasio penderita gizi buruk per seratus penduduk di Provinsi Banten berdasarkan PODES 2018

Hubungan kemiskinan dan kesehatan merupakan hubungan timbal balik yang tak terpisahkan. Kesehatan yang buruk dapat menyebabkan kemiskinan dan sebaliknya kemiskinan juga berpotensi menyebabkan keterbatasan akses kesehatan yang dapat membawa pada status kesehatan yang rendah. Terbatasnya akses layanan kesehatan pada kelompok miskin dapat menyebabkan kondisi kesehatan yang tidak menguntungkan sehingga dapat menyebabkan penurunan produktivitas yang memengaruhi penghasilan yang diperoleh dan pengeluaran ekonomi yang pada akhirnya akan menurunkan kualitas hidup dan menciptakan kemiskinan. Kondisi tersebut apabila terus berlangsung secara terus menerus dapat menyebabkan seseorang untuk terjebak dalam lingkaran kemiskinan atau bahkan memperdalam status kemiskinannya.

5.2.5. Kemiskinan dan Potensi Ekonomi

Inti dari masalah kemiskinan adalah ketersediaan pekerjaan. Pekerjaan memungkinkan orang untuk memproduksi untuk diri mereka sendiri (yaitu makanan) dan mendapatkan uang yang dibutuhkan untuk membeli barang dan jasa. Dari pekerjaan juga tercipta kekayaan yang akan tersalurkan melalui perpajakan sehingga memungkinkan pemerintah mendanai layanan yang berpihak pada kaum miskin seperti perawatan kesehatan, air

bersih, dan pendidikan. Namun, pekerjaan, lebih khusus lagi pekerjaan yang layak, tidak


mudah diciptakan. Pekerjaan yang layak akan berkembang dari sistem kegiatan ekonomi, sosial dan politik yang kompleks dan seimbang. Bekerja adalah inti dari pengentasan kemiskinan tetapi 'berusaha keluar dari kemiskinan' hanya memberikan panduan umum tentang bagaimana mencapainya tujuan akhir tersebut.

Bagi banyak orang miskin, bekerja berarti menjadi pemilik, atau karyawan di suatu usaha mikro atau kecil. Orang miskin seringkali bekerja sendiri, sebagai pemilik, pengelola, dan karyawan tunggal perusahaannya, atau melibatkan anggota keluarga, buruh harian lepas, dan pekerja tetap. Dalam banyak kasus, orang miskin memilih pekerjaan seperti itu karena mereka tidak punya banyak pilihan baik pekerjaan dengan bayaran yang memadai tidak tersedia maupun pekerjaan yang mereka lakukan di pertanian keluarga tidak cukup untuk memenuhi kebutuhan rumah tangga. Mereka berusaha keluar dari kemiskinan dengan bekerja untuk diri mereka sendiri. Pengembangan usaha kecil (UMKM) adalah sebuah upaya tentang menciptakan lingkungan sehingga pemilik dan pekerja dapat bekerja lebih cerdas, bekerja lebih aman, dan bekerja lebih produktif. Dengan demikian, mereka dapat mengurangi kemiskinan mereka. Inilah tantangan pengentasan kemiskinan melalui pengembangan usaha kecil.

Menurut Nursini (2020), secara umum, UMKM secara statistik mempengaruhi pengentasan kemiskinan di Indonesia baik secara langsung maupun tidak langsung. Namun demikian, skala usaha yang berbeda menawarkan berbagai implikasi bagi pengentasan kemiskinan. UKM memainkan peran yang lebih besar dalam mengentaskan kemiskinan daripada UMK karena mereka tidak hanya mengurangi persentase penduduk miskin tetapi juga Indeks Kesenjangan Kemiskinan dan Keparahan. Selanjutnya, dari keempat variabel kontrol, hanya pertumbuhan ekonomi yang berpengaruh signifikan terhadap pengentasan kemiskinan, baik secara langsung maupun tidak langsung.

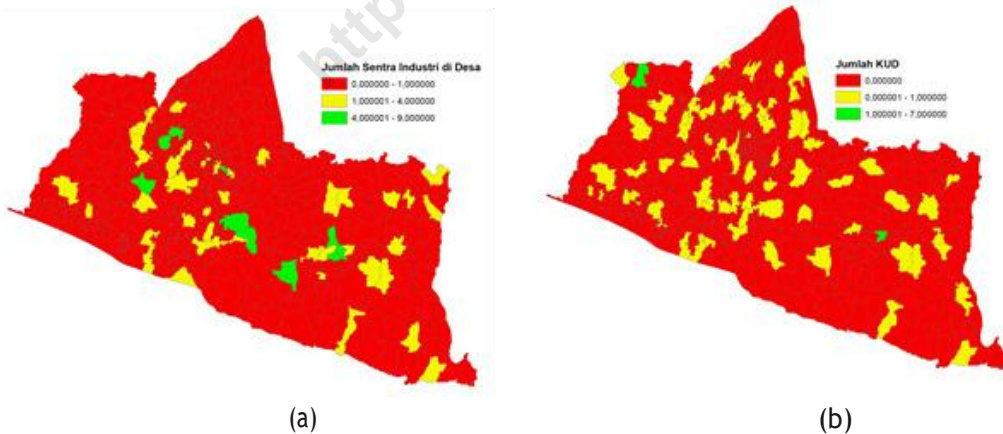
Pada Survei PODES 2018, terdapat variabel yang menggambarkan industri mikro dan kecil yang ada di desa. Selain mengenai jumlah industri, terdapat juga variabel mengenai sentra industri yang dapat digunakan untuk melihat potensi dari desa. Potensi pengembangan industri di Desa juga dapat dengan menggunakan variabel terkait dengan adanya KUD sebagai penyedia pendanaan dan pemberdayaan masyarakat desa.

Industri dan kemiskinan berdasarkan hasil PODES 2018 memiliki korelasi negatif. Dengan kata lain, Industri yang meningkat akan berasosiasi dengan tingkat kemiskinan keluarga yang rendah. Tingkat korelasi yang dihasilkan adalah sebesar -0,32 untuk kedua provinsi. Nilai korelasi ini memang cenderung rendah. Hal ini dikarenakan, jika melihat provinsi Banten, terdapat beberapa daerah yang memang memiliki anomali dan perbedaan klaster antara daerah yang dekat dengan Provinsi DKI Jakarta dan yang tidak.



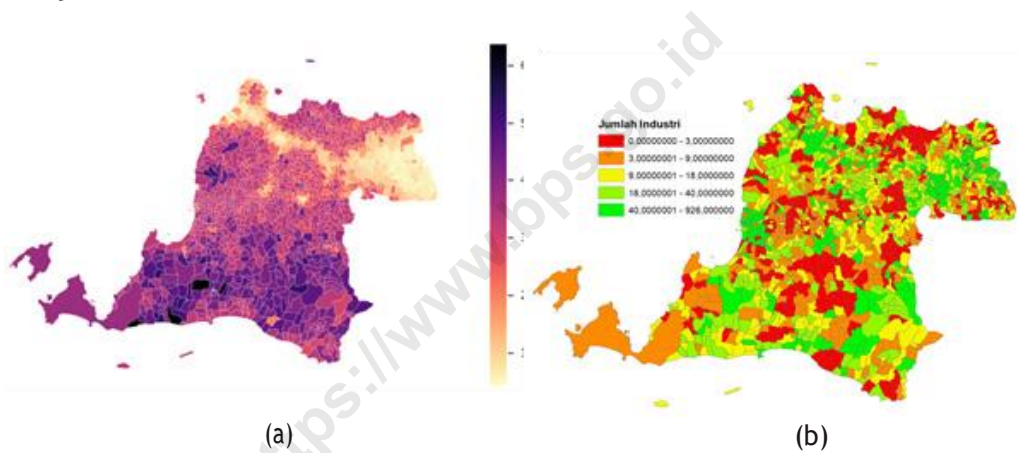
Gambar 5.18 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) sebaran jumlah industri di Provinsi D.I. Yogyakarta berdasarkan PODES 2018

Saat disandingkan, jumlah industri dan estimasi keluarga miskin memiliki asosiasi yang berlawanan arah. Desa yang memiliki banyak IMK, cenderung memiliki persentase keluarga miskin yang rendah. Sesuai dengan teori sebelumnya, IMK yang identik dengan masyarakat berskala kecil seperti keluarga cenderung akan menolong kondisi ekonomi untuk bertahan dalam pemenuhan kebutuhan sehari-harinya. Dengan kondisi ini, IMK dapat dikatakan sebagai salah satu solusi dalam pengentasan kemiskinan.



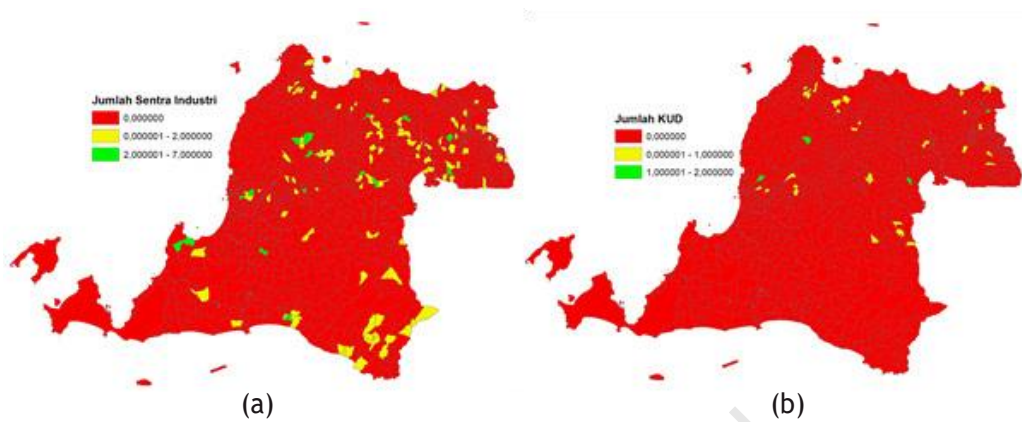
Gambar 5.19 Perbandingan (a) Sentra Industri da (b) jumlah KUD di Provinsi D.I. Yogyakarta berdasarkan PODES 2018

Kondisi Industri yang baik pada Provinsi DIY, nyatanya tidak memiliki support system yang cukup memadai. Sentra industri yang cenderung kurang merata serta kurangnya tersebar dengan baik dari KUD membuat adanya asumsi bahwa pertumbuhan industri dari desa-desa di Provinsi DIY masih kurang baik. Sentra industri merupakan salah satu wadah pemusatan industri mikro dan kecil yang menghasilkan produk sejenis, menggunakan input, serta adanya proses produksi yang sama dan dilengkapi dengan fasilitas berupa sarana penunjang. Adanya sentra industri tentu akan mengakomodasi industri desa yang memiliki produk dengan keunggulan komparatif. Di sisi lain, KUD juga dapat menjadi pondasi yang baik untuk pendanaan dari IMK sendiri. Dengan terbatasnya akses desa kepada lembaga keuangan, KUD dapat menjadi lembaga yang menjadi solusi.



Gambar 5.20 Perbandingan (a) persentase keluarga miskin hasil prediksi model, (b) sebaran jumlah industri di Provinsi Banten berdasarkan PODES 2018

Kondisi pada Provinsi Banten serupa dengan yang terjadi pada Provinsi DIY. Pada daerah yang memiliki kepadatan industri, tingkat kemiskinan keluarga cenderung lebih rendah. Namun, kondisi ini hanya berlaku pada daerah di Kota Tangerang dan Tangerang Selatan. Pada daerah selatan di Provinsi Banten, hal anomali justru terjadi. Daerah yang memiliki jumlah industri yang tinggi justru juga memiliki tingkat keluarga miskin yang juga tinggi. Anomali ini mungkin disebabkan oleh kondisi industri yang masih memiliki produktivitas rendah pada daerah selatan Provinsi Banten.



Gambar 5.21 Perbandingan (a) Sentra Industri da (b) jumlah KUD PODES 2018 di Provinsi Banten

Berdasarkan kondisi dari sentra industri yang ada, Provinsi Banten cenderung memiliki jumlah yang sedikit. Hal ini menyebabkan produktivitas industri yang mungkin terhambat. Di sisi lain, jumlah KUD yang juga cenderung sedikit juga menyebabkan kemungkinan produktivitas yang rendah dari IMK yang ada.

DAFTAR PUSTAKA



- Andriana, L., & Manaf, A. (2017). Relevansi Aspek Kemiskinan dan Fisik Lingkungan Kumuh Pada Penentuan Lokasi Penerima Program KOTAKU (Studi Kasus Kecamatan Pamekasan Kabupaten Pamekasan). *Jurnal Pengembangan Kota*, 5(2), 131-139.
- Aprianto, K., Wijayanto, A.W., Pramana, S., (2022). Deep Learning Approach using Satellite Imagery Data for Poverty Analysis in Banten, Indonesia. *Proceedings of the 2022 IEEE International Conference on Cybernetics and Computational Intelligence*
- Aryani, Y. & Wijayanto, A. W. (2021). Klasifikasi Pengembalian Radar dari Ionosfer Menggunakan SVM, Naive Bayes dan Random Forest. *Komputika: Jurnal Sistem Komputer*, 10(2), Universitas Komputer Indonesia
- Blair, Tony, Right Hon (2000) Speech on Knowledge Economy, 11 September, <http://www.opengov.uk>
- BPS. (2022). Teknik Pengumpulan Data dan Preprocessing Citra Satelit. BPS.
- Chen, T., & Guestrin, C. (2016). Xgboost: A Scalable Tree Boosting System. *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, (pp. 785-794).
- Chi, G., Fang, H., Chatterjee, S., & Blumenstock, J. E. (2022). Microestimates of wealth for all low-and middle-income countries. *Proceedings of the National Academy of Sciences*, 119(3)
- Dalilah, A., & Ridwana, R. (2019). Pemanfaatan Pengindraan Jauh Untuk Identifikasi Pemukiman Kumuh di Kota Bandung. *Jurnal Ilmiah Ilmu Sosial*, 5(2), 71-80.
- Dey, S.K., Hossain, A. & Rahman, M. M. (2018). Implementation of a Web Application to Predict Diabetes Disease: An Approach Using Machine Learning Algorithm. 2018 21st International Conference of Computer and Information Technology (ICCIT), pp. 1-5, doi: 10.1109/ICCITECHN.2018.8631968.
- Ekartaji, P., Yunus, H. S., & Rahardjo, N. (2016). Kajian Kualitas Lingkungan Permukiman di Daerah Pinggiran Kota Kasus di Desa Ngestiharjo, Yogyakarta. *Majalah Geografi Indonesia*, 28(1), 96-102.
- ESRI. 1998. ESRI Shapefile Technical Description.
- EUROSTAT (2019) Root Mean Square Error (RMSE).
https://ec.europa.eu/eurostat/cros/content/root-mean-square-error-rmse_en#:~:text=DEFINITION%3A,of%20variance%20and%20squared%20Bias
- Faturochman, & Molo, M. (1994). KARAKTERISTIK RUMAH TANGGA MISKIN DI DAERAH ISTIMEWA YOGYAKARTA. *Populasi*, 5, 1.
- Friedman, Jerome H. (2001). Greedy Function Approximation: A Gradient Boosting

- Machine. *Annals of statistics*, 1189-1232.
- Gebreslasie, M.T. (2015) A Review of Spatial Technologies with Applications for Malaria Transmission Modelling and Control in Africa. *Geospatial Health*, 10, 239-247. <https://doi.org/10.4081/gh.2015.328>
- Iman, Q. & Wijayanto, A. W. (2021). Klasifikasi Rumah Tangga Penerima Beras Miskin (Raskin)/Beras Sejahtera (Rastra) di Provinsi Jawa Barat Tahun 2017 dengan Metode Random Forest dan Support Vector Machine. *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, 9(2), pp. 178-184, Universitas Tanjungpura.
- Jean, N., Burke, M., Xie, M., Davis, W. M., Lobell, D. B., & Ermon, S. (2016). Combining satellite imagery and *machine learning* to predict poverty. *Science*, 353(6301), 790-794. <https://doi.org/10.1126/science.aaf7894>
- Khairunnisah, Wijayanto A.W., and Pramana S, Mapping Poverty Distribution of Urban Area Using VIIRS Nighttime Light Satellite Imageries in Yogyakarta, Indonesia. *Asian Journal of Business Environment*.
- Khomarudin R., Chulafak G.A., and Wijayanto, A.W., (2022). Peluang Dan Tantangan Pemanfaatan Penginderaan Jarak Jauh Untuk Mendukung Data Statistik Di Indonesia dalam Teknik Pengumpulan Data dan Preprocessing Citra Satelit. *BPS*.
- Kurniawan R., Saputra A.M.W., Wijayanto A.W., Caesarendra W., (2022). Eco-environment vulnerability assessment using *remote sensing* approach in East Kalimantan, Indonesia. *Journal Remote sensing Applications: Society and Environment*
- Lane, David M. et al. (2003). Introduction to Statistics. Tersedia dari Open Textbook Library.
- Ledesma, C., Garonita, O. L., Flores, L. J., & Tingzon, I. (2020). Interpretable Poverty Mapping using Social Media Data , Satellite Images , and Geospatial Information. *Thinking Machines Data Science*, 1-6.
- Li J (2017) Assessing the accuracy of predictive models for numerical data: Not r nor r^2 , why not? Then what?. *PLOS ONE* 12(8): e0183250. <https://doi.org/10.1371/journal.pone.0183250>
- Martinez, A., Addawe, M., Bulan, J. A. N., Durante, R. L., Fenz, K., & Hoffer, M. (2020). Mapping Poverty through Data Integration and Artificial Intelligence (Issue September). <https://www.adb.org/publications/mapping-poverty-dataintegration-ai>
- Marwala, T. (2018). Multi-layer Perceptron. In T. Marwala, *Handbook Of Machine Learning- Volume 1 Foundation Of Artificial Intelligence* (pp. 23-42). World Scientific.
- Mukaka MM. *Statistics corner: A guide to appropriate use of correlation coefficient*

- in medical research. *Malawi Med J.* 2012 Sep;24(3):69-71. PMID: 23638278; PMCID: PMC3576830.
- Ngestrini, R. (2019). Predicting Poverty of a Region from Satellite Imagery using CNNs.
- Nurkhaliza, A. A., & Wijayanto, A. W. (2022). Perbandingan Algoritma Klasifikasi Support Vector Machine dan Random Forest pada Prediksi Status Indeks Mitigasi dan Kesiapsiagaan Bencana (IMKB) Satuan Kerja BPS di Indonesia Tahun 2020. *Jurnal Informatika Universitas Pamulang*, 7(1), pp. 54-59, Universitas Pamulang.
- Oranga, J. , Obuba, E. and Nyakundi, E. (2020) Education as an Instrument of Poverty Eradication in Kenya: Successes and Challenges. *Open Journal of Social Sciences*, 8, 410-424. doi: 10.4236/jss.2020.89031.
- Park, Y., & Lek, S. (2016). Artificial neural networks: Multilayer perceptron for ecological modeling. In *Developments in environmental modelling* (pp. Vol. 28, pp. 123-140). Elsevier.
- Putri, N. B., & Wijayanto, A. W. (2022). Analisis Komparasi Algoritma Klasifikasi Data Mining Dalam Klasifikasi Website Phishing. *Komputika: Jurnal Sistem Komputer*, 11(1), pp.59-66.
- Putri, S. R., & Wijayanto, A. W. (2021). Learning Bayesian *Network* for Rainfall Prediction Modeling in Urban Area using *Remote sensing* Satellite Data (Case Study: Jakarta, Indonesia). *Proceedings of The International Conference on Data Science and Official Statistics*, 2021(1), 77-90. <https://doi.org/https://doi.org/10.34123/icdsos.v2021i1.37>
- Putri, S. R., Wijayanto, A. W., & Sakti, A. D. (2022). Developing Relative Spatial Poverty Index Using Integrated *Remote sensing* and Geospatial Big Data Approach: A Case Study of East Java, Indonesia. *ISPRS International Journal of Geo-Information*, 11(5), 275.
- Puttanapong, N., Martinez, A., Bulan, J. A. N., Addawe, M., Durante, R. L., & Martillan, M. (2022). Predicting poverty using geospatial data in Thailand. *ISPRS International Journal of Geo-Information*, 11(5), 293. <https://doi.org/10.3390/ijgi11050293>
- Riedmiller, M. (1994). Advanced supervised learning in multi-layer perceptrons—from backpropagation to adaptive learning algorithms. *Computer Standards & Interfaces* 16 (3), 265-278.
- Rizqina Putri, S. Wahyu Wijayanto, A. Pramana, S. 2021. Estimasi Pemetaan Kemiskinan dengan *Deep Learning* pada *Big Data* Fusi Citra Satelit Multisumber dan Point of Interest.

- Schowengerdt, R.A. (2006) *Remote sensing: Models and Methods for Image Processing*. Academic Press, Waltham.
- Shi, K., Chang, Z., Chen, Z., Wu, J., & Yu, B. (2020). Identifying and evaluating poverty using multisource *remote sensing* and point of interest (POI) data: A case study of Chongqing, China. *Journal of Cleaner Production*, 255, 120245. <https://doi.org/https://doi.org/10.1016/j.jclepro.2020.120245>
- Sintiawati, I. G. A. P. M. S., Wesnawa, I. G. A., & Suditha, I. N. (2014). Karakteristik dan Proses Terbentuknya Permukiman Kumuh di Wilayah Pesisir Desa Sangsit (Kasus Desa Sangsit). *Jurnal Jurusan Pendidikan Geografi*, 5(1), 1-10.
- Tingzon, I., Orden, A., Sy, S., Sekara, V., Weber, I., Fatehkia, M., Garcia, M., & Dohyung, H. (2019). Mapping Poverty in the Philippines Using *Machine learning*, Satellite Imagery, and Crowd-sourced Geospatial Information. *SPRS - International Archives of the Photogrammetry, Remote sensing and Spatial Information Sciences*, 42, 425-431. <https://doi.org/10.5194/isprsarchives-XLII-4-W19-425-2019>
- Wijayanto A.W., Afira N., Nurkarim W. (2022). *Machine learning* Approaches using Satellite Data for Oil Palm Area Detection in Pekanbaru City, Riau. *Proceedings of the 2022 IEEE International Conference on Cybernetics and Computational Intelligence*
- X. Yuan, L. Jia, J. Zhou, M. Menenti and Q. Chen, "A New Method for Noise Removal in Npp-Viirs Monthly Nighttime Light Imagery Over the Sahel Region," *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 2019, pp. 7467-7470, doi: 10.1109/IGARSS.2019.8897941.
- <https://www.scielo.br/j/neco/a/86kN8k6jTbhHFsxzsZkdY7C/?format=pdf&lang=en>
- <https://www.adb.org/publications/information-and-communications-technology-and-poverty-asian-perspective>
- <https://www.itu.int/net4/wsis/forum/2022/en/Agenda/Session/309>
- <https://www.oecd-ilibrary.org/docserver/9789264100206-en.pdf?expires=1656721577&id=id&accname=guest&checksum=A2E014178FCB91D2D16BE95BC4E6DACB>



<https://www.bps.go.id>



DATA

MENCERDASKAN BANGSA



BADAN PUSAT STATISTIK
BPS-Statistics Indonesia

Jl. dr. Sutoomo No. 6-8 Jakarta 10710
Telp: (021) 3841195, 3842508, 3810291-4, Fax: (021) 3857046
Homepage: <http://www.bps.go.id>, E-mail: bpsdq@bps.go.id

ISBN 978-602-438-520-0 (PDF)

