

Densely Connected Dan Residual Convolutional Neural Network untuk Estimasi Jumlah Keluarga Tingkat Desa Dengan Citra Satelit

Jodi Jhouranda Siregar¹, Anang Kurnia², Kusman Sadik³

^{1,2,3}Departemen Statistik, IPB University

Jl. Raya Darmaga, Bogor, Indonesia

¹Pengembangan Metodologi Sensus dan Survei, Badan Pusat Statistik

Jl. Dr. Sutomo No.6-8, Jakarta, Indonesia

e-mail: jodijhouranda@apps.ipb.ac.id¹, anangk@apps.ipb.ac.id², kusmans@apps.ipb.ac.id²

Received : September, 2022

Accepted : October, 2022

Published : October, 2022

Abstract

Indonesia conducts a population census every ten years to collect population data. Variables such as family count are collected to provide general population information for policy making and sampling frames. Indonesia as an archipelagic country with an area of 8.3 million km² will require a lot of resources to collect such data. In the age of big data, satellite imagery has become more available and inexpensive. In this study, we used West Java as a case study for applying deep learning to estimate family counts at the village level. Sentinel-2 and SPOT-67 data are used to model family counts. Using xgboost, we regress the family count with the softmax probability, resulting from family density classification using deep learning (densenet121 and resnet50) as the input. With an R² of 0.93 and a MAPE of 19%, the regression model provides a good prediction of the number of families in the census. Regarding the input data, Sentinel-2 is sufficient to accomplish this task as there is no significant difference from the modeling results with higher resolution images (SPOT 6-7). The input level in the form of a segment of the estimation area and using structured auxiliary variables also deliver better predictions.

Keywords: deep learning, remote sensing, xgboost, family count

Abstrak

Indonesia melakukan sensus penduduk setiap sepuluh tahun untuk mengumpulkan data kependudukan. Variabel seperti jumlah keluarga dikumpulkan untuk mendapatkan informasi populasi sebagai dasar penentuan kebijakan dan pembentukan kerangka sampel. Indonesia sebagai negara kepulauan dengan luas 8,3 juta km² akan membutuhkan banyak sumber daya untuk mengumpulkan data tersebut. Di era big data, citra satelit menjadi mudah dikumpulkan dan murah. Dalam studi ini, kami menggunakan Jawa Barat sebagai studi kasus untuk menerapkan deep learning untuk memprediksi jumlah keluarga di tingkat desa. Data satelit Sentinel-2 dan SPOT-67 digunakan untuk memodelkan jumlah keluarga. jumlah keluarga diregresi menggunakan xgboost dengan peluang softmax, yang dihasilkan dari klasifikasi jumlah keluarga menggunakan model deep learning (densenet121 dan resnet50) sebagai input. Model regresi memberikan prediksi yang baik untuk jumlah keluarga pada sensus dengan R² 0,93 dan MAPE 19%. Dari sisi input data, Sentinel-2 cukup untuk memberikan estimasi yang baik karena tidak ada perbedaan yang signifikan dari hasil pemodelan dengan gambar resolusi lebih tinggi (SPOT 6-7). Level input berupa segmen dari domain estimasi dan penggunaan structured auxiliary variable juga memberikan hasil prediksi yang lebih baik.

Kata Kunci: deep learning, remote sensing, xgboost, jumlah keluarga

1. PENDAHULUAN

Data kependudukan di Indonesia dikumpulkan melalui Sensus Penduduk (SP) pada tahun-tahun yang berakhir dengan angka nol oleh Badan Pusat Statistik (BPS). Data kependudukan bermanfaat sebagai dasar penentuan kebijakan publik. Selain itu, BPS memanfaatkan data SP sebagai kerangka sampel rumah tangga untuk melakukan survei di bidang sosial dan ekonomi. Untuk menghasilkan survei yang baik, kerangka sampel harus memenuhi syarat kelengkapan, akurat dan kemutakhiran[1]. Syarat ideal tersebut hampir tidak dapat dilakukan dengan pengumpulan data kependudukan yang tersedia. Data kependudukan yang tidak mutakhir dapat menyebabkan tidak tepatnya kebijakan dan menimbulkan permasalahan pada desain dan manajemen pelaksanaan survei dikarenakan kerangka sampel tidak sesuai dengan keadaan lapangan terkini.

Guna melengkapi data yang diperoleh dari sensus yang tidak mungkin dilaksanakan setiap tahun, berbagai metode pengumpulan dan pendugaan data kependudukan digunakan untuk mendapatkan informasi kependudukan terkini dan memutakhirkan variabel kependudukan yang digunakan sebagai kerangka sampel. Metode seperti survei, disagregasi spasial dan pendekatan *big data* telah digunakan sebagai alternatif sensus yang membutuhkan biaya besar. Survei Penduduk Antar Sensus (SUPAS) yang dilaksanakan pertengahan dua sensus dimanfaatkan untuk melakukan proyeksi jumlah penduduk[2]. Survei-survei lain di bidang sosial yang diselenggarakan BPS juga dimanfaatkan untuk melakukan pemutakhiran parsial kerangka sampel pada unit terpilih. Metode disagregasi spasial dikembangkan beberapa organisasi internasional untuk menghasilkan dugaan jumlah penduduk dan struktur kependudukan suatu negara. Worldpop, LandScan HD, dan GRID 3 menggunakan metode disagregasi spasial seperti *random forest* dan pendekatan bayesian untuk menduga jumlah penduduk di tingkat *grid* dengan data masukan jumlah populasi yang dirilis berbagai negara[3].

Memasuki era *big data*, data *remote sensing* mendapatkan banyak perhatian di berbagai bidang[4]. Termasuk pemanfaatannya untuk mengumpulkan dan menduga berbagai variabel

kependudukan. Robinson et al (2017) mengembangkan model estimasi jumlah penduduk di tingkat *county* di Amerika Serikat dengan melakukan *transfer learning* dari arsitektur *convolutional neural networks* (CNN) VGG-A. Model *deep learning* dikembangkan dengan data masukan data *grid* hasil disagregasi spasial. Pada penelitian tersebut kombinasi model *deep learning* dan *gradient boost* menghasilkan dugaan dengan R2 sebesar 0.9365[5]. Hu et al (2019) mengembangkan model estimasi kepadatan penduduk untuk tingkat wilayah yang lebih kecil. Untuk memetakan data hilang populasi rural di India Hu et al menggunakan citra sentinel-1 dan landsat-8 di tingkat desa yang dikonversi ke JPEG sebagai rangkaian data masukan dua arsitektur CNN untuk mengestimasi kepadatan penduduk pada tingkat desa. Dua model *deep learning* yang dikembangkan belum menghasilkan koefisien determinasi yang baik ($R^2 = 0.438$) untuk menduga kepadatan penduduk di tingkat desa[6]. Walaupun demikian model tersebut berhasil memberikan dugaan yang lebih baik untuk tingkat sub distrik dengan luas wilayah lima kali lebih kecil dari penelitian Robinson et al. Pada tahun 2021, Huang et al melakukan penelitian dengan data masukan *grid* dari Landscan HD untuk membandingkan berbagai arsitektur *deep learning* yaitu, VGG, Resnet, Xception dan Densenet untuk menduga jumlah penduduk di tingkat *county*. Dari hasil penelitian tersebut DenseNet memberikan prediksi jumlah penduduk. Xception dan Resnet yang menghasilkan kebaikan prediksi relatif sama menempati urutan berikutnya[7]. VGG yang digunakan Robinson et al dan Hu et al dalam penelitiannya menempati urutan terakhir. Selain perbandingan arsitektur *deep learning*, penelitian ini juga mempertimbangkan efek ketetanggaan dalam model yang malah mengurangi kualitas prediksi jumlah penduduk. Kesimpulan ini bertentangan dengan penelitian Xing et al (2020) yang menyimpulkan bahwa efek ketetanggaan meningkatkan kualitas estimasi dalam kasus pemetaan volume aktivitas 18 kota di Cina[8].

Berdasarkan penjelasan di atas, pemanfaatan *deep learning* sebagai metode baru untuk memodelkan data di bidang kependudukan semakin banyak dikembangkan. Hal ini dikarenakan potensi *big data* sebagai sumber data biaya rendah, berskala besar, dan rutin

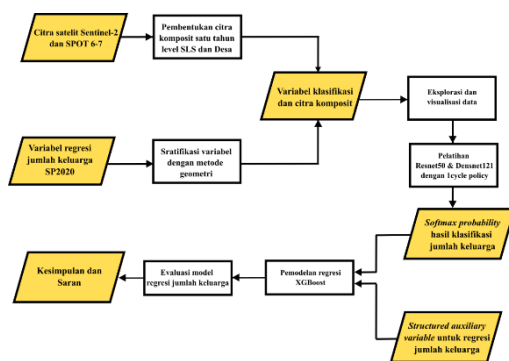
dimutakhirkan[9]. Untuk itu, pada penelitian ini pendekatan *deep learning* akan diterapkan untuk mengestimasi jumlah keluarga di tingkat desa di Provinsi Jawa Barat dengan memanfaatkan *best practice* dan *lesson learn* dari penelitian sebelumnya (jumlah penduduk) sebagai informasi awal pengembangan model. Pemilihan karakteristik jumlah keluarga dikarenakan variabel tersebut merupakan indikator penting untuk melihat potensi desa sekaligus merupakan variabel stratifikasi dan *size* kerangka sampel klaster di Indonesia.

Berdasarkan hal tersebut, model *deep learning densely connected network* (densenet)[10] dan *residual network* (resnet)[11] diterapkan pada regresi jumlah keluarga dengan memanfaatkan data satelit Sentinel-2[12] dan SPOT-67[13] untuk memprediksi jumlah keluarga di tingkat desa di Provinsi Jawa Barat. Model *deep learning* tidak digunakan secara langsung untuk regresi jumlah keluarga. Hal ini dikarenakan, dari berbagai pengumpulan data keluarga yang telah dilakukan di Indonesia terdapat banyak

structured data yang berpotensi sebagai *auxiliary variable* untuk meningkatkan prediksi jumlah keluarga. Untuk menggabungkan *unstructured data* berupa citra satelit dan *structured auxiliary variable*, model *deep learning* dimanfaatkan sebagai metode ekstraksi fitur dengan mengubah permasalahan regresi jumlah keluarga ke bentuk klasifikasi. Hasil prediksi peluang klasifikasi dimanfaatkan bersama dengan *structured auxiliary variable* sebagai data masukan model Xgboost. Hal ini serupa dengan metode penelitian Robinson et al yang menyatakan bahwa metode tersebut memberikan kualitas prediksi lebih baik daripada prediksi langsung melalui *deep learning* walaupun tanpa menyertakan *structured auxiliary variable*. Selain itu, XGboost yang merupakan *derivative-free model* diharapkan dapat memberikan performa lebih baik dari model *deep learning* untuk mengatasi permasalahan dengan *degree of freedom* yang lebih tinggi (regresi)[14].

2. METODE PENELITIAN

Secara umum, penelitian ini akan dilakukan dengan alur metode pada Gambar 1.



Gambar 1 Diagram alir regresi jumlah keluarga

2.1 Pembentukan Citra Satelit


Peubah bebas pada penelitian ini merupakan citra komposit satu tahun satelit Sentinel-2 dan Citra SPOT 67 LAPAN di tingkat desa dan satuan lingkungan setempat (SLS) di Jawa Barat. Berdasarkan penelitian Hu et al, input di tingkat yang lebih kecil meningkatkan performa model agregat di tingkat wilayah yang lebih besar. Proses pembentukan citra untuk masukan *deep learning* dilakukan pada citra satelit Sentinel-2 berskala 10m maupun Data SPOT 6-7 LAPAN berskala 1,5m. Data tingkat desa diubah

menjadi ukuran 224x224 *pixel* dan data tingkat SLS menjadi 64x64 *pixel* untuk tujuan efisiensi komputasi

Untuk Data Sentinel 2 citra diproses seperti pada. Poligon desa hasil Pemetaan SP2020 dimanfaatkan sebagai batas definitif untuk setiap desa di Jawa Barat. Batas definitif desa digunakan sebagai dasar menghitung batas persegi desa. Kemudian, batas tersebut digunakan untuk mengunduh seluruh *clip* citra desa 3 *band* Sentinel-2 pada periode 1 Januari-31 Desember 2020. Citra yang dipilih adalah citra dengan tutupan awan di bawah 30%. Kumpulan citra satelit yang tersedia untuk periode tersebut dibentuk menjadi citra komposit dengan menghitung nilai median pada setiap *band*. Kemudian, citra satelit di tingkat desa yang telah diunduh akan di-*clip* menjadi citra satelit di tingkat SLS dan Desa.

Untuk data *raster* SPOT 67 dari LAPAN, data masukan *deep learning* disiapkan dengan melakukan *clip raster* seperti pada proses untuk Sentinel-2. Sehingga, Pada penelitian ini tersedia dua jenis data citra satelit dengan skala 10m dan 1.5m (Gambar 2). Menurut Sabottke et al (2020) penggunaan citra beresolusi lebih tinggi dapat meningkatkan performa model klasifikasi *deep learning* untuk

kasus data radiologi[15]. Berdasarkan teori tersebut, pada penelitian ini akan diuji efek resolusi pada model identifikasi karakteristik desa dengan data citra satelit. Uji efek resolusi citra satelit akan dilakukan setelah dipilih model *deep learning* dan *auxiliary* terbaik untuk melakukan prediksi jumlah keluarga di tingkat desa. Sehingga pada tahap awal, citra Sentinel-2 akan digunakan.




Gambar 2 : Citra sentinel-2 dan SPOT-67


2.2 Pembentukan Variabel Respon

Variabel jumlah keluarga diubah menjadi permasalahan klasifikasi untuk mempermudah proses pemodelan jumlah keluarga dengan citra satelit dan *structured auxiliary variable (Aux)*. Untuk itu, variabel jumlah keluarga terlebih dahulu distratifikasi dengan menggunakan metode geometrik yang diperkenalkan oleh Gunning dan Horgan[16]. Metode ini membentuk batas stratifikasi (b_h) sehingga variabel jumlah keluarga akan menjadi klasifikasi jumlah keluarga dengan kelas sebanyak .

$$b_h = \text{Min}(Y_{jk}) \times [\text{Max}(Y_{jk}) / \text{Min}(Y_{jk})]^{h/l} \quad (1)$$



Gambar 3 : Model densenet121



Gambar 4 : Model resnet50

2.3 Klasifikasi Jumlah Keluarga

Kedua model klasifikasi *deep learning* (resnet50 dan densenet121) dilatih dengan *smith's 1cycle policy* dengan *circular learning rate* untuk setiap model data[17], [18]. Model klasifikasi yang dibentuk memprediksi kelas karakteristik desa di tingkat desa dan SLS dengan menghitung peluang sebuah citra termasuk dalam satu kelas tertentu dengan menggunakan peluang aktivasi *softmax* (p_i) di akhir layer *deep learning*.

$$p_i = e^i / \sum e^i \quad (2)$$

Untuk variabel jumlah keluarga, peluang prediksi untuk setiap kelas dan *structured auxiliary variable* dimanfaatkan sebagai data masukan pemodelan regresi pohon

XGBoost[19] untuk mendapatkan dugaan regresi jumlah keluarga.

2.4 Pemodelan Regresi Pohon XGBoost untuk Jumlah Keluarga

Pada proses sebelumnya, telah dibentuk dua model klasifikasi jumlah keluarga dengan menggunakan Resnet50 dan Densenet121. Hasil prediksi peluang di setiap kelas klasifikasi dan *structured auxiliary variabel* digunakan sebagai data masukan model regresi pohon XGBoost. Input dipasangkan dengan jumlah keluarga (numerik) yang bersesuaian yang disimbolkan dengan D . Simbol p_h peluang hasil aktivasi *softmax* kelas ke-h dan aux_1 dan aux_2 merupakan *structured auxiliary variabel* berupa kategori desa urban/rural dan luas desa.

$$D=\{(x_i, y_j^k)\}$$

(3)

$$X_i = (p_1, p_2, p_3, \dots, p_h, aux_1, aux_2)$$

(4)

Tabel 1 : Kombinasi input dan model regresi jumlah keluarga

Input			Model ekstraksi fitur	Model regresi
Satelit	Tingkat citra	Auxiliary		
Sentinel-2	Desa	-	Densenet121	Xgboost
Sentinel-2	Desa	√	Densenet121	Xgboost
Sentinel-2	Desa	-	Resnet50	Xgboost
Sentinel-2	Desa	√	Resnet50	Xgboost
Sentinel-2	SLS	-	Densenet121	Xgboost
Sentinel-2	SLS	√	Densenet121	Xgboost
Sentinel-2	SLS	-	Resnet50	Xgboost
Sentinel-2	SLS	√	Resnet50	Xgboost

Seluruh kombinasi data masukan seperti pada Tabel 1 digunakan untuk melatih model regresi xgboost dengan metode *grid search hyper-parameter tuning*. Kombinasi nilai *learning rate, max depth, minimum child weight, subsample, colsample by tree*, dan *number of estimator* dilatih dan *hyper-parameter* terbaik dipilih dengan memilih model dengan *mean squared error* terkecil. Nilai *hyper-parameter* yang digunakan dapat dilihat pada Tabel 2. Dugaan jumlah keluarga akan dilakukan dengan menjumlahkan pohon regresi dengan *hyper-parameter* terbaik hasil pelatihan sebelumnya. Untuk mendapatkan dugaan jumlah keluarga di tingkat administrasi lebih tinggi, dilakukan agregasi dugaan jumlah keluarga di tingkat SLS sampai tingkat desa.

Tabel 2 : Daftar nilai hyper-parameter

Hyper-parameter	Nilai
Learning rate	[0.05,0.025,0.01]
Max depth	[3,6,10,15]
Minimum child weight	[3,5,11]
Subsample	[0.8,0.9,1]
Colsample by tree	[0.7,0.9]
Number of estimator	[10,50,100,250,500]

2.5 Evaluasi Model

Pada proses ini akan digunakan k-fold dengan k=5 untuk mengevaluasi model.

- Dugaan jumlah keluarga dibandingkan dengan data hasil SP2020. Metrik evaluasi yang akan disusun untuk memeriksa kebaikan prediksi model dan data hasil sensus di tingkat desa adalah R^2 , *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE).
- Evaluasi hasil prediksi regresi dengan visualisasi prediksi dan residual.

- Evaluasi efek resolusi citra terhadap performa model
- Terakhir, dipilih model terbaik untuk ketiga variabel respon berdasarkan metrik evaluasi yang telah disusun.

3. HASIL DAN PEMBAHASAN

3.1 Stratifikasi Variabel Respon Jumlah Keluarga

Untuk variabel jumlah keluarga yang masih bertipe numerik diubah menjadi bentuk kategorik dengan proses stratifikasi menggunakan Gunning Horgan *geometry stratification method* untuk menghasilkan stratifikasi tingkat desa dan SLS yang cenderung seimbang untuk data menceng. Proses stratifikasi tidak hanya dilakukan berdasarkan hasil formula saja, dilakukan *adjustment* dengan penggabungan atau pemisahan hasil stratifikasi guna mendapatkan kelas yang lebih seimbang tanpa kehilangan jumlah stratifikasi yang diharapkan (delapan). Hasil stratifikasi dapat dilihat pada Tabel 3.

Tabel 3 : Interval stratifikasi level desa dan SLS


kelas	Interval Desa	Interval SLS
1	154.32 - 319.73	0 - 38.65
2	319.73 - 663.81	38.65-50
3	663.81 - 1378.17	50-65.15
4	1378.17 - 2861.31	65.15-80
5	2861.31 - 5940.54	80-109.82
6	5940.54 - 12333.53	109.82-145
7	12333.53 - 25606.39	145-185.12
8	25606.39 - 53163	185.12-4245

3.2 Eksplorasi Data


untuk meningkatkan model regresi jumlah keluarga dapat digunakan pendekatan penggunaan *auxiliary variable* yang memiliki hubungan dengan jumlah keluarga. Penggunaan xgboost sebagai regresi

memungkinkan pemanfaatan data terstruktur dan hasil fitur ekstraksi *deep learning* untuk memodelkan hal tersebut.

Auxiliary variable pertama yang berpotensi meningkatkan kualitas prediksi adalah klasifikasi desa urban/rural. Dapat dilihat bahwa penduduk yang tinggal di daerah urban memiliki pola yang berbeda dari daerah rural seperti yang dapat dibandingkan antara Gambar 5 & Gambar 6. Desa dengan jumlah keluarga tinggi (ditandai dengan warna kuning pada Gambar 6) cenderung merupakan desa dengan klasifikasi desa urban, dan sebaliknya.




Gambar 5 : Peta tematik klasifikasi desa urban dan rural di Jawa Barat tahun 2020



Gambar 6 : Peta tematik jumlah keluarga berdasarkan desa di Jawa Barat tahun 2020

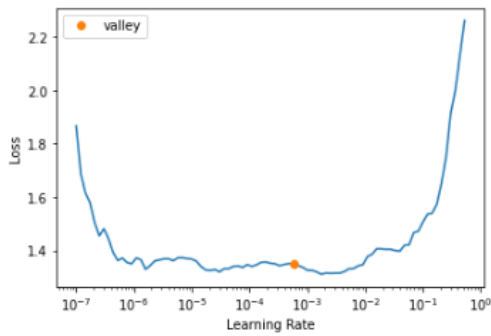
Selain klasifikasi urban/rural, Pada Gambar 7 dapat dilihat terdapat pula pola hubungan tidak linear antara luas wilayah dan jumlah keluarga. Hubungan tersebut dapat dimanfaatkan dalam pemodelan regresi XGBoost yang dapat mempelajari pola tak linear dari variabel respon dan input.



Gambar 7 : Scatter plot jumlah keluarga dan luas desa di Jawa Barat.

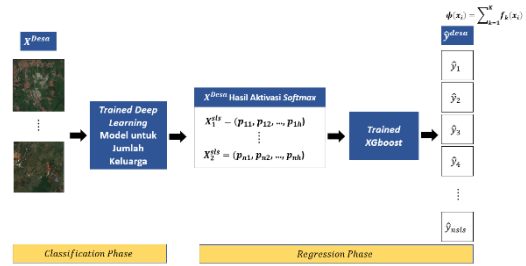
3.3 Pemodelan Regresi Jumlah Keluarga

Untuk mendapatkan estimasi jumlah keluarga dilakukan dua tahapan pemodelan, yaitu tahap klasifikasi dan tahap regresi. Tahap klasifikasi dilakukan untuk menghasilkan prediksi peluang *softmax* untuk masing-masing kelas tingkat jumlah keluarga yang sudah dibentuk sebelumnya. Proses pemodelan klasifikasi *deep learning* *densenet121* dan *resnet50* dilakukan pada citra tingkat desa dan SLS. Proses pelatihan model dilakukan dengan metode *Smith's 1cycle policy* untuk mendapatkan hasil terbaik dengan proses pelatihan yang lebih efisien. Untuk menentukan batas maksimum learning rate di lakukan plot antara *learning rate* dan *loss* guna mencari titik balik dimana *learning rate* Kembali menghasilkan *loss* yang cenderung tinggi. Gambar 8 menunjukkan model memberikan *loss* cenderung menaik pada nilai *learning rate* di atas 10^{-2} sehingga pada *1cycle policy* digunakan titik tersebut sebagai batas maksimum *learning rate*.



Gambar 8 : Plot *learning rate* dan *loss*

Berikutnya, pemodelan regresi XGBoost untuk jumlah keluarga memanfaatkan peluang untuk input di level desa maupun SLS seperti pada Gambar 9. *Auxiliary variable* dari data terstruktur ditambahkan pada X^{desa} hasil aktivasi *softmax*. Khusus input SLS, ditambahkan proses agregat untuk mendapatkan estimasi di tingkat desa.



Gambar 9 : Proses prediksi jumlah keluarga

Tahap pelatihan model regresi xgboost dilakukan dengan mencari *hyper-parameter* terbaik dengan proses *grid parameter search*. Setiap model dievaluasi dengan validasi silang *k-fold* ($k=5$) dengan membandingkan MSE terkecil dari kombinasi *hyper-parameter* pada Tabel 2. Sehingga, untuk setiap model dilatih 5400 model xgboost. Hasil penelitian ini menunjukkan perbedaan *hyper-parameter* terbaik untuk masing-masing model, baik dengan input desa maupun SLS seperti yang dapat dilihat pada Tabel 4 & Tabel 5.

Tabel 4 : *Hyper-parameter* terbaik xgboost untuk input tingkat desa

<i>Hyper-parameter</i>	DensenetDesa	DensenetDesa+ Aux	ResnetDesa	ResnetDesa+ Aux
<i>Learning rate</i>	0.025	0.025	0.05	0.05
<i>Max depth</i>	3	3	3	3
<i>Minimum child weight</i>	5	5	3	3
<i>Subsample</i>	0.8	0.9	1	0.9
<i>Colsample by tree</i>	0.9	0.7	0.7	0.9
<i>Number of estimator</i>	250	250	100	100

Tabel 5 : *Hyper-parameter* terbaik xgboost untuk input tingkat SLS

<i>Hyper-parameter</i>	Densenet SLS	Densenet SLS+ Aux	Resnet SLS	Resnet Desa Aux
<i>Learning rate</i>	0.01	0.01	0.01	0.05
<i>Max depth</i>	10	10	10	3
<i>Minimum child weight</i>	11	11	11	3
<i>Subsample</i>	0.8	0.8	0.8	0.9
<i>Colsample by tree</i>	0.9	0.7	0.9	0.9
<i>Number of estimator</i>	500	500	500	100

Tabel 6 : Hasil evaluasi model regresi jumlah keluarga estimasi tingkat desa

Model	Aux	MAE	R ²	MAPE
DensenetDesa	-	781.47	0.67	0.35
DensenetDesa	√	757.14	0.69	0.32
ResnetDesa	-	806.59	0.64	0.35
ResnetDesa	√	794.99	0.65	0.34
DensenetSLS	-	420.02	0.91	0.19
DensenetSLS	√	414.72	0.91	0.19
ResnetSLS	-	427.33	0.91	0.20
ResnetSLS	√	421.67	0.91	0.19

3.4 Evaluasi Model Regresi Jumlah Keluarga

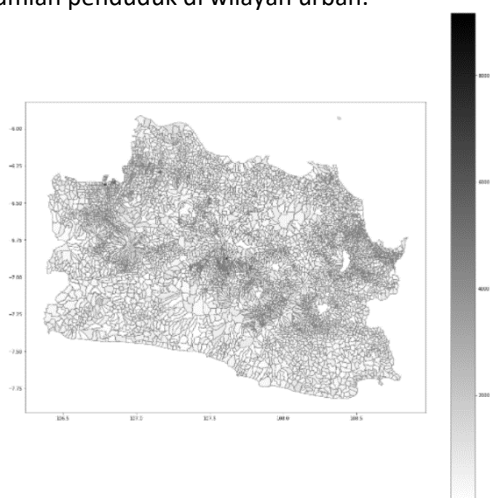
Model regresi xgboost jumlah keluarga yang telah dilatih dengan *hyper-parameter* terbaik dengan menggunakan data hasil aktivasi *softmax* dan *auxiliary variable* urban/rural dan luas wilayah dievaluasi dengan menggunakan metrik R² dan MAE ,dan MAPE.

Tabel 6 merupakan hasil evaluasi regresi jumlah keluarga untuk estimasi di tingkat desa. Dari tabel tersebut, model regresi memberikan

performa yang baik untuk estimasi level desa baik dengan menggunakan input hasil aktivasi *softmax* di level SLS maupun desa. Walaupun demikian, input tingkat SLS lebih baik daripada input di tingkat desa karena dapat menurunkan sekitar 35% MAE, 15% MAPE, dan R^2 meningkat sekitar 0.25. Untuk arsitektur model *deep learning*, hasil klasifikasi dari densenet lebih baik dari pada resnet untuk seluruh kasus perbandingan.

Di sisi lain, *auxiliary* luas wilayah dan klasifikasi urban/rural sedikit meningkatkan performa model. Model hanya meningkatkan 1% MAPE dan MAE. Model tidak dapat mempelajari dengan baik hubungan tak linear antara luas area dan jumlah keluarga dan perbedaan distribusi jumlah keluarga di kelas desa urban dan rural. Sehingga diperlukan *auxiliary* yang lain untuk meminimalkan kesalahan estimasi regresi pada model.

Peta tematik *residual* juga disusun untuk mengevaluasi hasil prediksi jumlah keluarga. Pada Gambar 10, dapat dilihat *residual* lebih besar terjadi di wilayah urban dengan membandingkan dengan Gambar 5. Hal tersebut dapat dilihat lebih jelas pada Tabel 7. Tabel menunjukkan *residual* lebih tinggi yang terjadi di wilayah urban sejalan dengan lebih tingginya jumlah penduduk di wilayah urban.



Gambar 10 : Peta tematik *residual* prediksi jumlah keluarga di provinsi Jawa barat

Walaupun telah digunakan informasi klasifikasi urban/rural sebagai *auxiliary variable* model regresi *xgboost*, variabel tersebut belum berhasil membedakan struktur jumlah keluarga di wilayah urban dan rural. Sehingga dibutuhkan informasi lebih di penelitian berikutnya seperti keberadaan rumah susun, apartemen atau sejenisnya yang memungkinkan model melihat perbedaan infrastruktur fisik wilayah urban sebagai tempat tinggal keluarga dengan harapan estimasi yang dihasilkan lebih mendekati nilai sesungguhnya di semua klasifikasi wilayah.

Tabel 7 : Perbandingan MAE pada wilayah urban dan rural

Klasifikasi	Rata-rata JK	MAE
Urban	2859.26	447.26
Rural	1391.88	275.16

Evaluasi lain yang dilakukan pada penelitian ini adalah dengan membandingkan hasil estimasi jumlah keluarga dengan penelitian serupa lainnya yang mengestimasi jumlah penduduk dengan menggunakan model *deep learning*. Perbandingan dilakukan pada dua jenis variabel yang berbeda dikarenakan penelitian sebelumnya tidak mengestimasi jumlah keluarga, akan tetapi dengan eratnya hubungan kedua variabel tersebut diharapkan dapat memberikan gambaran umum performa model dari sisi lain. Tabel 8 menunjukkan penelitian ini berhasil mengestimasi untuk domain estimasi lebih kecil dengan input dan model yang berbeda dengan penelitian sebelumnya. Dimana dapat dipelajari input citra satelit yang merupakan segmen dari domain estimasi dapat meningkatkan performa prediksi model

Tabel 8 : perbandingan hasil dengan penelitian sebelumnya

Jurnal	Proposed	Hu 2020	Robinson 2017
Variabel	Family Count	Population Count	Population Count
Tingkat input	SLS	Desa	Disagregasi spasial
Lokasi studi	INA	India	US
Domain estimasi	Desa	Subdistrik	county
Luas domain estimasi	6.63 km ² km ²	424 km ² km ²	2584 km ² km ²
Model	DensenetSLS+XGBoost	Deep Combo	CONVRAW
R ²	0.913	0.931	0.910
MAPE	19.2	21.5	73.8

Terakhir, dilakukan evaluasi dampak citra satelit terhadap performa model. Model terbaik dengan densenetSLS+Xgboost tanpa diterapkan ulang pada citra satelit Sentinel-2 dan SPOT-6-7 untuk menguji efek resolusi citra terhadap kualitas prediksi keluarga. Pada Tabel 9 terlihat data SPOT memberikan sedikit kebaikan prediksi pada setiap metrik. Walaupun demikian, kebaikan prediksi yang didapatkan tidak cukup besar apabila dibandingkan dengan biaya pengumpulan dan komputasi data SPOT untuk mendapatkan prediksi jumlah keluarga.

Tabel 9 : Perbandingan model regresi citra Sentinel-2 dan SPOT-67

Satelit	MAE	R ²	MAPE
Sentinel	425.74	0.91	0.19
SPOT	390.86	0.93	0.17

4. KESIMPULAN

Dari uraian di atas dapat disimpulkan :

- Model *deep learning* densenet merupakan model terbaik untuk melakukan ekstraksi fitur citra satelit.
- Model xgboost cukup baik memprediksi jumlah keluarga di tingkat desa dengan R² sebesar 0.913 dan MAPE 19%.
- Input citra terbaik untuk regresi jumlah keluarga tingkat desa adalah citra dengan input level SLS. Citra sentinel cukup untuk memprediksi jumlah keluarga di tingkat desa dengan metode penelitian ini. Citra SPOT hanya meningkatkan sedikit performa model.
- Structured auxiliary variable* dan resolusi citra memberikan dampak positif pada performa model.

Terdapat pula beberapa saran untuk penelitian selanjutnya:

- Menambahkan data observasi dari provinsi lain di Indonesia untuk meningkatkan

performa model dengan menambah variasi amatan.

- Menambahkan informasi berupa *structured data* pada model xgboost untuk membantu meminimalkan kesalahan prediksi, terutama pada desa urban. Informasi mengenai perbedaan struktur hunian pada wilayah urban dan rural dapat dijadikan dasar penentuan *auxiliary variable*.
- Hasil regresi dan klasifikasi banyak ditentukan dari pola infrastruktur sebuah desa yang pada umumnya tidak berubah dalam waktu yang singkat, sehingga perlu ditambahkan variabel lain yang berubah relatif cepat untuk melakukan analisis perubahan karakteristik desa jangka pendek.

PERNYATAAN PENGHARGAAN

Ucapan terima kasih kepada Badan Pusat Statistik dan IPB University yang telah mendukung seluruh proses penelitian ini.

DAFTAR PUSTAKA

- [1] J. Bethlehem and S. Biffignandi, *Handbook of Web Survey*. 2011. doi: 10.1002/9781118121757.
- [2] BPS, *Proyeksi Penduduk Indonesia 2015-2045 Hasil SUPAS 2015*. 2015.
- [3] C. A. Hill et al., *Big Data Meets Survey Science: A Collection of Innovative Methods*. 2020. doi: 10.1002/9781118976357.
- [4] G. Cheng, X. Xie, J. Han, L. Guo, and G. S. Xia, "Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 13, 2020, doi: 10.1109/JSTARS.2020.3005403.
- [5] C. Robinson, F. Hohman, and B. Dilkina, "A deep learning approach for population estimation from satellite

- imagery," 2017. doi: 10.1145/3149858.3149863.
- [6] W. Hu *et al.*, "Mapping missing population in rural India: A deep learning approach with satellite imagery," 2019. doi: 10.1145/3306618.3314263.
- [7] X. Huang, D. Zhu, F. Zhang, T. Liu, X. Li, and L. Zou, "Sensing population distribution from satellite imagery via deep learning: Model selection, neighboring effects, and systematic biases," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 14, 2021, doi: 10.1109/JSTARS.2021.3076630.
- [8] X. Xing *et al.*, "Mapping Human Activity Volumes through Remote Sensing Imagery," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 13, 2020, doi: 10.1109/JSTARS.2020.3023730.
- [9] E. Suel, S. Bhatt, M. Brauer, S. Flaxman, and M. Ezzati, "Multimodal deep learning from satellite and street-level imagery for measuring income, overcrowding, and environmental deprivation in urban areas," *Remote Sens Environ*, vol. 257, 2021, doi: 10.1016/j.rse.2021.112339.
- [10] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2017, vol. 2017-January. doi: 10.1109/CVPR.2017.243.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016, vol. 2016-December. doi: 10.1109/CVPR.2016.90.
- [12] M. Drusch *et al.*, "Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services," *Remote Sens Environ*, vol. 120, 2012, doi: 10.1016/j.rse.2011.11.026.
- [13] S. E. O. R. EO, "SPOT-6 and 7 - eoPortal Directory - Satellite Missions," *EO, Sharing Earth Observation Resources*, 2016.
- [14] C. Chen, T., & Guestrin, "A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794).," *J Assoc Physicians India*, 2016.
- [15] C. F. Sabottke and B. M. Spieler, "The effect of image resolution on deep learning in radiography," *Radiol Artif Intell*, vol. 2, no. 1, 2020, doi: 10.1148/ryai.2019190015.
- [16] P. Gunning and J. Horgan, "Improving the Lavallée and Hidiroglou algorithm for stratification of skewed populations," *J Stat Comput Simul*, vol. 77, no. 4, 2007, doi: 10.1080/10629360600569170.
- [17] L. N. Smith, "Disciplined Approach To Neural Network," *arXiv:1803.09820v2 [cs.LG]*, 2018.
- [18] L. N. Smith, "Cyclical learning rates for training neural networks," 2017. doi: 10.1109/WACV.2017.58.
- [19] J. Chen, D. Liang, Z. Zhu, X. Zhou, Z. Ye, and X. Mo, "Social media popularity prediction based on visual-textual features with XGboost," 2019. doi: 10.1145/3343031.3356072.