

TINJAUAN PEMANFAATAN BIG DATA PENGINDERAAN JAUH DAN PEMBELAJARAN MESIN UNTUK OFFICIAL STATISTICS DI WILAYAH PERKOTAAN

Arif Handoyo Marsuhandi¹, Dwi Wahyu Triscowati², Arie Wahyu Wijayanto³

¹Badan Pusat Statistik RI, ²Badan Pusat Statistik Kabupaten Banyuwangi, ³Politeknik Statistika STIS
e-mail: ¹arifhandoyo@bps.go.id

Abstrak

Kemajuan teknologi big data tidak hanya menawarkan potensi pemanfaatan namun juga tantangan bagi penyelenggaraan official statistics. Sebagai salah satu sumber big data yang potensial, data spektral penginderaan jauh yang tersedia secara terbuka dan gratis menjadi modal berharga untuk penyempurnaan kualitas official statistics. Makalah ini meninjau peluang dan tantangan pemanfaatan penginderaan jauh di wilayah perkotaan dan menyajikan studi kasus awal pada monitoring pertumbuhan lanskap perkotaan di Indonesia. Studi kasus awal ini menggunakan metode pembelajaran mesin ansambel sebagai model untuk klasifikasi, yaitu random forest yang merupakan pendekatan statistik nonparametrik dengan penerapan agregasi dan bootstrapping pada pohon keputusan. Penelitian ini mengambil fokus pada Kabupaten Banyuwangi, Provinsi Jawa Timur sebagai studi kasus. Hasil eksperimen dengan citra satelit Landsat-8 menunjukkan keberhasilan model dalam mendeteksi perubahan area bangunan selama 6 tahun pertumbuhan lanskap perkotaan pada 2015-2020. Terhitung pada tahun 2015 dan 2020, model yang dibangun dapat mendeteksi bangunan/konstruksi dengan akurasi masing-masing 93 dan 91 persen. Kesimpulan sementara ini membuka kemungkinan penerapan penginderaan jauh untuk menunjang survei dan sensus statistik pada wilayah perkotaan, khususnya sebagai salah satu indikator penting untuk penghitungan nilai tambah bruto (NTB) lapangan usaha konstruksi yang menjadi komponen dari Produk Domestik Regional Bruto (PDRB).

Kata kunci: *big data, official statistics, penginderaan jauh, pembelajaran mesin, wilayah perkotaan*

Abstract

Big data provides not only great potential benefits but also major challenges in official statistics. As one of the most popular big data sources, remote sensing spectral data from openly available satellites offers abundant potential in helping the quality improvement of official statistics. In this paper, we identify the potential and challenges of remote sensing in urban areas and review a pilot study of urban landscape growth monitoring in Indonesia. We use an ensemble machine learning method, random forest, which acts as a nonparametric statistical based on aggregated and bootstrapped decision trees in regression problems. This work take place in Banyuwangi Regency, East Java Province as research study area. Our result demonstrates the ability of the model to detect building changes during 6 years urban growth period in 2015-2020. Our model is able to detect the building/built-up construction in 2015 and 2020 with accuracy rate of 93 and 91 percent respectively. Our finding sheds light on the promising remote sensing implementation in supporting statistical surveys and census in urban areas, especially as one of the essential indicators to calculate the Gross Added Value (GVA) of the construction sector which further becomes a component of the Gross Regional Domestic Product (GRDP).

Keywords: *big data, official statistics, remote sensing, machine learning, urban area*

PENDAHULUAN

Data spektral penginderaan jauh yang tersedia secara gratis dan bebas akses menawarkan potensi sumber big data yang berharga untuk penyempurnaan kualitas official statistics. Data penginderaan jauh terbuka yang telah disediakan oleh satelit penginderaan Landsat-8, Sentinel-1, Sentinel-2, dst yang mencakup juga seluruh wilayah di Indonesia dalam bentuk multi-spektral dan antar waktu. Wilayah perkotaan saat ini mengalami perkembangan pesat, terutama perubahan lanskap perkotaan dan adanya pertumbuhan bangunan-bangunan dan jalan baru. Adanya pertumbuhan bangunan tersebut diantaranya mencerminkan kenaikan jumlah penduduk, urbanisasi, pembukaan lahan-lahan tempat tinggal baru, dan pertumbuhan ekonomi di sektor konstruksi.

Pesatnya perkembangan wilayah perkotaan menuntut official statistics untuk terus berupaya

menyediakan data perubahan wilayah perkotaan. Data tersebut dapat berupa perkembangan luasan bangunan, pertumbuhan jalan, komposisi penggunaan lahan, neraca konstruksi, ekonomi lingkungan, urbanisasi, dan sebagainya. Dengan adanya peningkatan teknologi penginderaan jauh dalam penyediaan citra satelit, saat ini penelitian untuk wilayah perkotaan dapat memanfaatkan citra satelit tersebut sebagai sumber datanya. Berbagai jenis citra satelit tersedia secara gratis dan dapat diakses oleh siapapun. Data citra satelit tersebut mencakup seluruh wilayah Indonesia serta memiliki resolusi spasial dan temporal yang terus meningkat. Beberapa contoh yang dapat dimanfaatkan adalah Landsat-8, Sentinel-1, dan Sentinel-2 (Yang, 2018; You, 2018; Schulg, 2020; Pelizari, 2018).

Data citra satelit potensial untuk digunakan sebagai sumber data, namun jika pemrosesan

dilakukan secara manual, perlu kerja keras dan kurang praktis apabila diterapkan pada skala regional atau nasional. Perlu dilakukan pengembangan metode yang

dapat mendeteksi bangunan secara otomatis atau minimal semiotomatis. Oleh karena itu dalam studi ini digunakan metode pembelajaran mesin khususnya random forest agar model dapat memanfaatkan informasi dari banyak fitur untuk mendeteksi bangunan.

Sejumlah indeks fitur yang banyak digunakan untuk mendeteksi bangunan diantaranya adalah

normalized difference built-up index (NDBI). Penggunaan NDBI ini cukup efektif akan tetapi pada area non bangunan yang terdapat banyak tanah pertanian terbuka (sedang tidak ditanami), lahan tandus, jalan yang tidak tergenangi air, dan beberapa objek lain juga memiliki nilai-nilai NDBI yang mirip dengan bangunan. Jadi perlu penambahan indeks lain ketika deteksi dilakukan secara global untuk seluruh lahan. Contohnya indeks air seperti normalized difference water index (NDWI), indeks kehijauan seperti enhanced vegetation index (EVI), dan indeks-indeks lainnya. Selain itu perubahan indeks antar waktu juga penting untuk mendeteksi bangunan dan non bangunan ini. Sebagai contoh, lahan tandus sesekali akan tetap ditumbuhi oleh rerumputan kehijauan sehingga dalam rentang waktu tertentu nilai EVI akan meningkat dan NDBI akan turun, sementara nilai indeks NDBI bangunan cenderung tidak banyak perubahan dalam beberapa rentang waktu kecuali ada perubahan dari non bangunan menjadi bangunan ataupun sebaliknya.

Makalah ini mencoba mengimplementasikan penginderaan jauh dan pembelajaran mesin di Kabupaten Banyuwangi, Provinsi Jawa Timur sebagai studi kasus. Kabupaten Banyuwangi sebagai salah satu kabupaten yang terus tumbuh di Jawa Timur, mencatatkan pertumbuhan bangunan/konstruksi dari tahun ke tahun. Pada tahun 2010, peranan sektor konstruksi dalam perekonomian Kabupaten Banyuwangi sebesar 10,39 persen, meningkat menjadi 11,33 persen di tahun 2015 dan meningkat kembali menjadi 13,48 persen di tahun 2018 (BPS Banyuwangi, 2019).

Meskipun citra satelit dan pembelajaran mesin potensial digunakan untuk menyediakan data perubahan lahan perkotaan, di sisi lain terdapat pula beberapa tantangan yang perlu dihadapi dalam pemanfaatannya. Oleh karenanya, dalam ulasan makalah ini akan dipelajari tinjauan pemanfaatan big data penginderaan jauh dan pembelajaran mesin untuk wilayah perkotaan.

METODE

Pengumpulan data label dilakukan menggunakan Google Earth Pro pada tanggal tangkap citra di bulan Juni tahun 2015 dan 2020. Jenis citra satelit yang digunakan untuk klasifikasi bangunan adalah citra Landsat-8 yang telah dikoreksi geometric dan radiometric (Landsat-8 Surface Reflectance). Analisis data dalam penelitian ini dilakukan pada komputer dengan spesifikasi prosesor Intel® core™ i3 CPU @ 2.00 Ghz 64bit RAM 4.00 GB.

Titik sampel setiap tahun yang digunakan sebanyak 50 bangunan, 16 air, 43 sawah, 73 hutan dan tumbuhan, dan 9 lain-lain. Proses penggabungan data label dengan data citra satelit sampai dengan pengklasifikasian lahan dan tampilan peta di lakukan di Google Earth Engine (GEE). Analisis lanjutan seperti penghitungan luasan ataupun tampilan peta hasil analisis di lakukan menggunakan R versi 3.5.1. dengan package yang digunakan adalah `datatable`, `raster`, `rgdal`, `sp`, `PBSmapping`, dan `RColorBrewer`.

Tahapan Penelitian

Sesuai dengan tujuannya, tahapan penelitian secara umum terdiri dari empat tahap, yaitu penyusunan data label, pemrosesan data, klasifikasi, dan analisis lanjutan (seperti penghitungan luasan dan pengecekan perubahan wilayah non bangunan ke bangunan). Secara rinci, tahapan penelitian yang dilakukan untuk setiap tahun sebagai berikut:

1. Penyusunan data label:

- a. Pengambilan titik koordinat sampel setiap kelas berdasarkan pandangan mata dari google earth pro tangkapan citra satelit setiap bulan Juni tahun

2015 dan 2020. Simpan file sampel ini dalam bentuk CSV.

- b. Pengolahan titik koordinat menjadi spasial point dengan R versi 3.5.1. Pertama pemberian CRS projection berupa longlat dan datum WGS84, lakukan `spTransform`, lalu simpan dalam bentuk shapefile.
 - c. Upload shapefile tersebut dalam bentuk assets di GEE melalui alamat <https://code.earthengine.google.com/>
- ### 2. Pemrosesan data:
- a. Data citra satelit yang digunakan adalah data landsat yang telah dilakukan koreksi radiometric maupun geometric, sehingga citra yang dipilih di GEE adalah `LANDSAT/LC08/C01/T1_SR`.
 - b. Lakukan filter awan dengan kriteria batas tutupan awan kurang dari 50 persen dan bayangan awan kurang dari 30 persen.
 - c. Pilih band (B1, B2, B3, B4, B5, B6, B7, B10, B11) dan indeks (NDVI, NDBI, NDWI, dan EVI) yang akan digunakan. Hitung nilai maksimum, minimum, mean, dan median setiap band dan indeks dalam rentang waktu januari-juni. Buat komposit citra januari-juni dari band dan indeks yang digunakan.
- ### 3. Klasifikasi
- a. Ambil data nilai komposit maksimum, minimum, mean, dan median setiap band dan indeks pada titik koordinat data label yang akan digunakan untuk pembentukan model.
 - b. Bagi data secara acak menjadi data latih dan data uji dengan perbandingan 70:30.
 - c. Gunakan data latih untuk membentuk model random forest dan data uji untuk menghitung akurasi dan kappa model.
 - d. Gunakan model yang terbentuk untuk melakukan prediksi tutupan lahan semua wilayah di Banyuwangi.
 - e. Lakukan plot hasil klasifikasi dengan membuat add layer hasil klasifikasi.
 - f. Eksport hasil klasifikasi tersebut ke google drive dengan skala 30 m × 30

m sehingga hasil klasifikasi dapat diunduh dalam bentuk Tiff.

4. Analisis lanjutan
 - a. Unduh hasil klasifikasi dari google drive. Buka di R versi 3.5.1. menggunakan fungsi stack pada package raster.
 - b. Rubah dalam bentuk dataframe, luasan setiap pixel adalah 900 m² karena setiap pixel berukuran 30 m × 30 m. Hitung luasan setiap kelas.
 - c. Plot peta klasifikasi menggunakan warna colorRampPalette.
 - d. Identifikasi sebaran tiap kelas, terutama untuk kelas bangunan dengan memilih pixel-pixel yang terklasifikasikan sebagai bangunan.
 - e. Identifikasi adanya perubahan wilayah, misalkan pilih pixel yang semula bukan bangunan kemudian menjadi bangunan.

Random Forest

Random forest (Breiman, 2001) merupakan metode klasifikasi terbimbing yang menerapkan bagging dan random feature selection, yaitu memilih secara acak beberapa fitur dalam setiap iterasinya. Jumlah dan jenis fitur yang digunakan untuk membentuk pohon dalam setiap iterasi tidak sama atau acak sehingga random forest ini cenderung tidak terpengaruh adanya multikolinieritas antar fitur. Jadi dalam pembentukan model random forest dapat diujikan penggunaan fitur sebanyak-banyaknya untuk menangkap fitur-fitur terbaik yang bersesuaian dengan tujuan klasifikasi. Tahapan dalam random forest sebagai berikut:

1. Bootstrap, penarikan contoh berukuran n dengan pemulihan yang akan digunakan untuk membentuk satu pohon
2. Subsetting, pemilihan p fitur sebagai penyekat untuk membangun sebuah pohon, nilai $p < q$, dengan q adalah seluruh fitur yang ada. Pemilihan berbagai ukuran p memungkinkan hasil prediksi lebih baik jika menggunakan nilai p yang berbeda.
3. Pengulangan langkah 1 dan 2 sampai diperoleh k pohon

4. Prediksi akhir merupakan dugaan gabungan berdasarkan majority vote dari k pohon tersebut.

TANTANGAN KLASIFIKASI BANGUNAN VS NON BANGUNAN

Proses penyusunan data label untuk klasifikasi bangunan dan non bangunan ini tidak serumit daripada penyusunan data label untuk klasifikasi tanaman. Hal ini dikarenakan kenampakan bangunan di citra satelit cukup jelas, sehingga pengambilan sampel data dapat dilakukan dengan pandangan mata terhadap citra satelit periode tertentu ataupun menggunakan data titik koordinat bangunan dan non bangunan dari sumber lain seperti survei ataupun peta sebaran bangunan dan non bangunan. Namun proses klasifikasi bangunan dan non bangunan ini juga memiliki tantangan. Secara umum tantangan klasifikasi bangunan menggunakan citra satelit adalah kompleksitas data citra satelit dan adanya tutupan lahan. Secara khusus beberapa tantangan lain diantaranya yaitu:

1. Deteksi bangunan dilakukan terhadap pancaran spektral atap bangunan, padahal bangunan memiliki berbagai jenis atap yang berbeda, diantaranya ada yang genteng tanah liat, beton, asbes, seng, kaca, maupun bahan-bahan alami seperti rumbia, ijuk, dan jerami. Setiap jenis atap akan menyebabkan nilai pancaran spektral band yang berbeda-beda.
2. Saat sering turun hujan, pancaran spektral akan sedikit bias. Contoh, diasumsikan bahwa bangunan adalah lahan kering, namun nilai indeks air antara hutan dan bangunan bisa saja mirip ketika tangkapan citra terjadi setelah turun hujan karena lahan hutan maupun atap bangunan sama-sama basah.
3. Adanya pancaran spektral area non bangunan yang mirip bangunan seperti tanah pertanian sedang panen atau bera kering, lahan kering tandus, hutan jati yang meranggas atau rerumputan yang mengering saat musim panas, tanah terbuka seperti lapangan, jalan-jalan yang kering seperti jalan tanah kering

dan jalan aspal atau beton. Ketika pancaran spektral band area non bangunan mirip dengan bangunan, maka nilai indeks yang diturunkan pun akan mirip. Akibatnya akan menyebabkan salah klasifikasi antar bangunan dan non bangunan karena data input yang digunakan antar kelas mirip.

4. Cara penurunan kesalahan klasifikasi antar bangunan dan non bangunan karena ada area non bangunan yang mirip bangunan, dapat dilakukan dengan memasukkan nilai perubahan band atau indeks antar waktu (secara temporal). Perubahan nilai band atau indeks bangunan antar waktu cenderung lebih stabil daripada perubahan nilai antar waktu pada non bangunan. Misalkan suatu hutan jati yang meranggas di musim panas, pada saat musim hujan hutan jati tersebut juga tingkat kehijauannya tinggi. Artinya terdapat perubahan nilai indeks kehijauan antar musim di hutan jati, sementara nilai indeks kehijauan bangunan antar musim relatif stabil.
5. Kemiripan perubahan antar waktu antara bangunan dan non bangunan dapat terjadi pada bangunan-bangunan yang baru dibangun karena nilai band sebelumnya cukup berbeda. Kemiripan lain dapat terjadi pada lahan non bangunan yang sepanjang tahun tidak banyak perubahan seperti lahan kering yang pancaran spektralnya mirip dengan bangunan.
6. Pengurangan kesalahan klasifikasi bangunan berdasarkan klasifikasi pixel dimungkinkan dengan penggabungan klasifikasi pixel dan klasifikasi objek. Pada penelitian ini, klasifikasi bangunan hanya didasarkan klasifikasi pixel saja.

CITRA SATELIT DAN PEMBELAJARAN MESIN SEBAGAI SUMBER DATA WILAYAH PERKOTAAN

Pertumbuhan perkotaan dan penduduk yang dinamis menuntut adanya data yang up to date. Perkiraan berbasis penginderaan jauh dianggap sebagai sumber yang tepat untuk memantau

perubahan dinamis ini dalam jangka panjang. Citra satelit memiliki periode tangkap yang cukup cepat, misalkan sentinel-1 dan sentinel-2 setiap 5 hari, sedangkan Landsat-8 setiap 16 hari. Dari dua jenis citra satelit ini saja, pemantauan wilayah perkotaan dapat dilakukan pada level bulanan jika diperlukan.

Biasanya, data-data official statistik diterbitkan dalam rentang waktu 1 tahun kemudian, yaitu data tahun 2019 diterbitkan di tahun 2020. Pada penelitian ini telah dapat ditampilkan data luasan bangunan tahun 2020. Sehari setelah tanggal perekaman citra satelit, data tersebut telah dapat diakses di GEE, sehingga analisis dapat segera dilakukan. Minimal, data hasil analisis menggunakan citra satelit tersebut sudah dapat di terbitkan pada bulan selanjutnya. Misalkan hasil analisis untuk bulan Juni 2020, dapat dilakukan di bulan Juli 2020.

Sebagai salah satu cara agar data hasil analisis citra satelit dapat segera diperoleh adalah penggunaan metode-metode otomatis atau semi otomatis seperti machine learning. Ketika model pembelajaran mesin ini telah diperoleh, misalkan model pembelajaran mesin dari data bulan Juni tahun 2019, model tersebut dapat digunakan untuk memprediksi perubahan wilayah perkotaan tahun 2019 bulan selanjutnya ataupun memprediksi tahun 2020. Proses prediksi dilakukan cukup dengan membentuk fitur yang sama dengan fitur yang digunakan dalam pemodelan.

Metode pemodelan lain yang dapat digunakan untuk analisis citra satelit ini dapat dilakukan dengan metode klasifikasi lain, baik klasifikasi tidak terbimbing seperti clustering, klasifikasi terbimbing seperti maximum likelihood, ataupun pembentukan model linier seperti regresi. Namun metode-metode tersebut hanya menggunakan sejumlah fitur terbatas untuk klasifikasi. Padahal teknologi penginderaan jauh saat ini terus mengalami perkembangan yang pesat dan banyak satelit diluncurkan dengan jenis sensor yang lebih canggih. Berbagai jenis citra satelit diproduksi dengan tingkat ketajaman pixel,

periode, dan kanal band yang berbeda-beda. Informasi dari periode dan kanal-kanal band tersebut dapat diturunkan menjadi puluhan fitur yang dapat digunakan untuk meningkatkan akurasi klasifikasi pada area yang lebih luas dan kompleks sehingga klasifikasi akan lebih maksimal jika banyak fitur dimanfaatkan untuk pembentukan model.

Selain dengan pemodelan, analisis terhadap citra satelit ini dapat dilakukan secara manual, yaitu memilih satu persatu pixel bangunan dan non bangunan berdasarkan tampilan mata. Metode ini mungkin akan presisi hasilnya untuk citra satelit dengan ketajaman pixel tinggi, namun proses pemilihan pixel akan memakan waktu ketika dilakukan di area yang luas.

SIMULASI PEMANFAATAN CITRA SATELIT UNTUK PERKEMBANGAN WILAYAH KABUPATEN BANYUWANGI

Tinjauan pemanfaatan citra satelit dan random forest untuk melihat perubahan wilayah perkotaan dilakukan di Kabupaten Banyuwangi, Jawa Timur sebagai studi kasus. Model klasifikasi yang terbentuk digunakan untuk mengklasifikasikan wilayah Banyuwangi setiap tahun menjadi lima kelas, yaitu bangunan (1), air (2), sawah (3), hutan dan pepohonan (4), serta lainnya (5).

Kelas sawah dan hutan diambil tanpa mempertimbangkan perbedaan jenis tanaman. Sementara kelas lainnya adalah kelas selain bangunan, air, sawah, hutan dan pepohonan. Sampel yang diambil untuk kelas ini contohnya lapangan terbuka seperti gelanggang olahraga dan tanah terbuka di sekitar bandara, maupun lahan-lahan terbengkalai bukan sawah yang tidak ditanami pepohonan. Akibatnya muncul beberapa kesalahan klasifikasi seperti area hutan yang pohon-pohonnya telah ditebangi sebagai kelas lainnya. Akan tetapi karena fokus penelitian dilakukan untuk bangunan dan non bangunan saja, maka banyaknya kesalahan klasifikasi kelas lainnya ini tidak dianalisis lebih lanjut.

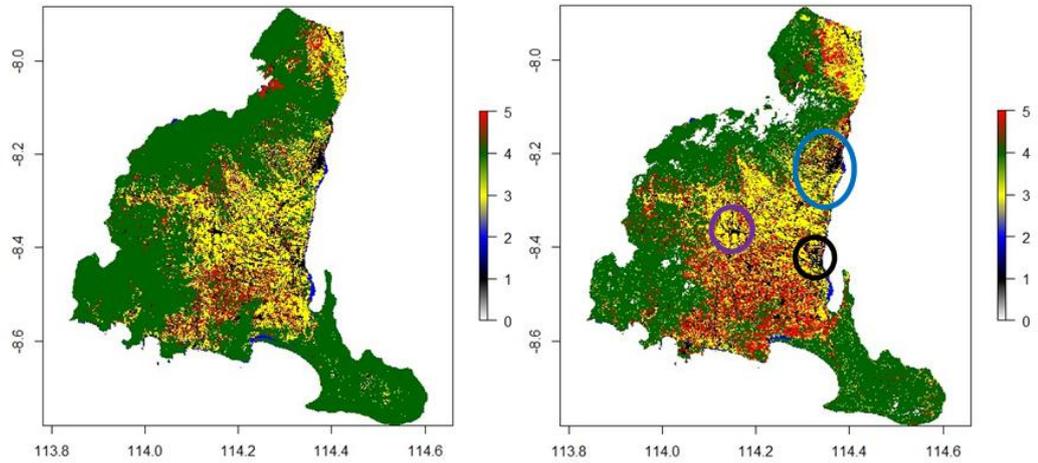
Hasil klasifikasi Banyuwangi tahun 2015 dan 2020 yang ditampilkan pada

Gambar 1 untuk melihat perubahan wilayah perkotaan dalam rentang 5 tahunan. Terdapat 5 kelas klasifikasi dengan warna yang berbeda, yaitu bangunan (warna hitam), air (warna biru), sawah (warna kuning), hutan dan pohon-pohonan (warna hijau), dan kawasan lainnya (warna merah).

Area pusat penduduk di Banyuwangi adalah daerah pusat kota Kecamatan Banyuwangi dan Rogojampi (lingkaran biru Gambar 1.b), pusat kota bagian barat Kecamatan Genteng (lingkaran ungu Gambar 1.b), dan pusat perikanan Kecamatan Muncar (lingkaran hitam Gambar 1.b). Pertumbuhan bangunan baru banyak terjadi di daerah perkotaan dan sebagian menyebar sampai daerah pinggiran yang mengkonversi wilayah sawah dan hutan (lingkaran kuning Gambar 1.d). Lahan sawah dan hutan yang terkonversi menjadi bangunan banyak terjadi di area selatan, yaitu Kecamatan Siliragung, Purwoharjo, sampai Tegaldlimo, dan daerah utara, yaitu Kecamatan Wongsorejo. Kenampakan perubahan yang lebih jelas dari non bangunan (tahun 2015) menjadi bangunan (tahun 2020) terlihat pada Gambar 1.e. Sementara area yang dari tahun 2015 sampai 2020 tetap menjadi bangunan terlihat pada sebaran pixel Gambar 1.f.

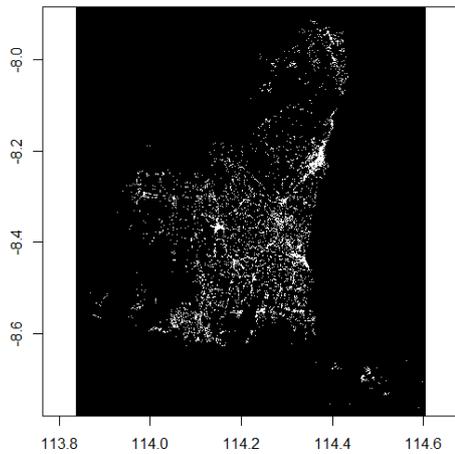
Baik model tahun 2015 maupun 2020 memperoleh tingkat akurasi diatas 90 persen dengan kappa 91 persen di tahun 2015 dan 88 persen di tahun 2020. Ketika dilihat luasan bangunannya pun nampak bahwa terjadi pertumbuhan bangunan sebesar 2.671 Hektar. Pertumbuhan luasan bangunan tersebut dapat di breakdown menjadi pertumbuhan bangunan di setiap kecamatan ketika dilakukan cropping per kecamatan, namun pada penelitian ini batasan penelitian dilakukan pada level kabupaten saja.

Meskipun tidak dilakukan penghitungan luasan sampai level kecamatan, dari Gambar 1.e terlihat bahwa pertumbuhan bangunan baru terjadi menyebar di hampir semua kecamatan bahkan sampai daerah-daerah pinggiran yang semula di tahun 2015 tidak ada bangunan. Pusat pertumbuhan bangunan

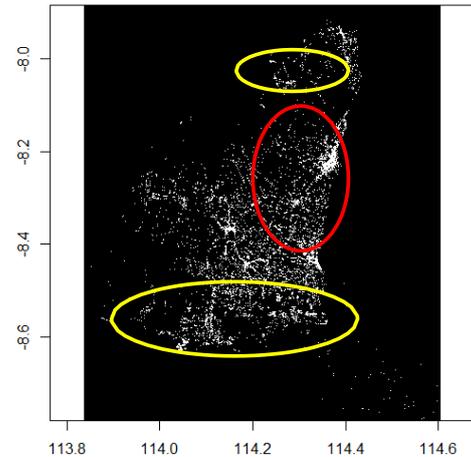


a) Klasifikasi tahun 2015

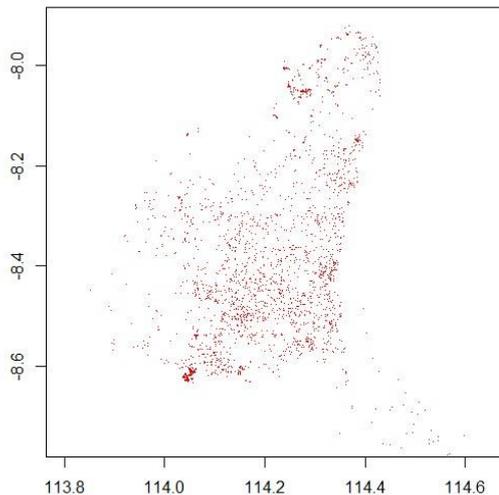
b) Klasifikasi tahun 2020



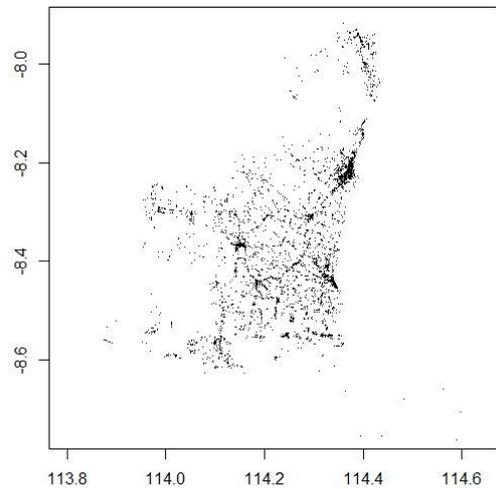
c) Posisi Bangunan 2015



d) Posisi Bangunan 2020



e) Non-bangunan (2015) menjadi bangunan (2020)



e) Tetap bangunan dari tahun 2015 ke 2020

Gambar 1. Pertumbuhan Kawasan Bangunan Perkotaan (Dilingkari Merah) dan Kawasan Bangunan yang Mengkonversi Wilayah Sawah Dan Hutan (Dilingkari Kuning).

nampak pada area dengan pixel yang cukup padat seperti Siliragung, Purwoharjo,

Muncar, dan Wongsorejo. Hasil simulasi di kabupaten Banyuwangi ini menunjukkan

adanya kemampuan model dalam mendeteksi perubahan area bangunan selama pertumbuhan lanskap perkotaan tahun 2015-2020.

KESIMPULAN

Dari hasil simulasi di Kabupaten Banyuwangi, dapat disimpulkan dengan tingkat akurasi yang melebihi 90 persen pada dua amatan tahun yang berbeda bahwa pemanfaatan big data penginderaan jauh dan pembelajaran mesin untuk wilayah perkotaan dapat dilakukan dengan sangat baik dan menghasilkan model klasifikasi yang akurat. Pemanfaatan penginderaan jauh dan pembelajaran mesin dapat dilakukan dari sisi klasifikasi tutupan lahan pada waktu tertentu maupun dari sisi perubahan lahan atau alih fungsi tutupan lahan. Beberapa masalah yang ditemui dalam penelitian ini dari sisi teknis adalah masalah tutupan awan yang tidak dapat dihindari, penelitian selanjutnya diharapkan dapat mengatasi permasalahan tersebut.

Secara lebih khusus, identifikasi peningkatan kepadatan dan luas bangunan secara deret waktu dapat menjadi salah satu indikator penting untuk penghitungan nilai tambah bruto (NTB) lapangan usaha konstruksi yang menjadi komponen dari Produk Domestik Regional Bruto (PDRB).

DAFTAR PUSTAKA

BPS Banyuwangi. (2019). Produk Domestik Regional Bruto Kabupaten Banyuwangi Menurut Lapangan Usaha 2015-2019. BPS

Breiman L. (2001). Random Forests. *Machine Learning* 45, pages 5–32

Gómez, J. A., Patiño, J. E., Duque, J. C., and S. Passos. (2020). Spatiotemporal modeling of urban growth using machine learning. *Remote Sensing*, 12(1).

Gorelick N, Hancher M, Dixon M, Ilyushchenko S, Thau D, Moore R. (2017). Google Earth Engine: Planetary- scale geospatial analysis for everyone. *Remote Sensing of Environment* 202:18–27

Li M, Koks E, Taubenbock H, van Vliet J. (2020). Continental-scale mapping and analysis of 3D building structure. *Remote Sensing of Environment* 245:111859

Nie, Z., K., Chan, K. Y., and B. Xu. (2019). Preliminary evaluation of the consistency of Landsat 8 and Sentinel-2 time series products in an urban area-an example in Beijing, China. *Remote Sensing*, 11(24). Osgouei, P. E., Kaya, S., Sertel, E., and U. Alganci. (2019). Separating built-up areas from bare land in mediterranean cities using Sentinel-2a imagery. *Remote Sensing*, 11(3), 1–24.

Pelizari P A, Sprohnlé K, Geis C, Schoepfer E, Plank S, Taubenbock H. (2018). Multi-sensor feature fusion for very high spatial resolution built-up area extraction in temporary settlements. *Remote Sensing of Environment* 209:793–807

Rahman, M. M., Avtar, R., Yunus, A. P., J. Dou, P. Misra, W. Takeuchi, N. Sahu, P. Kumar, B. A. Johnson, R.

Dasgupta, A. Kharrazi, S. Chakraborty, and T. A. Kurniawan. (2020). Monitoring effect of spatial growth on land surface temperature in Dhaka. *Remote Sensing*, 12(7).

Schug F, Frantz D, Okujeni A, van der Linden S, Hostert P. (2020). Mapping urban-rural gradients of settlements and vegetation at national scale using Sentinel-2 spectral-temporal metrics and regression- based unmixing with synthetic training data. *Remote Sensing of Environment* 246:111810

Triscowati, D. W., Sartono, B., Kurnia, A., Domiri, D. D., and Wijayanto, A. W. (2020). Classification of rice- plant growth phase using supervised random forest method based on landsat-8 multitemporal data. *International Journal of Remote Sensing and Earth Science*, 16(2), 81–90.

Triscowati, D. W., Sartono, B., Kurnia, A., Domiri, D. D., and Wijayanto, A. W. (2019). Multitemporal remote sensing

data for classification of food crops plant phase using supervised random forest. Sixth Geoinformation Science Symposium, 1131102, SPIE, 10.

Yang X, Qin Q, Grussenmeyer P, Koehl M. (2018). Urban surface water body detection with suppressed built-up noise based on water indices from Sentinel-2 MSI imagery. *Remote Sensing of Environment* 219:259–270

You, J., Li, X., Low, M., Lobell, D., & Ermon, S. (2017). Deep Gaussian Process for Crop Yield Prediction Based on Remote Sensing Data. 31th AAAI Conference on Artificial Intelligence, 4559–4565.

