

Model Klasifikasi Fase Pertumbuhan Tebu dari Citra Sentinel 1 Multi-temporal Menggunakan Algoritma *Random Forest*

Classification Model of Sugarcane Growth Phase from Multi-temporal Sentinel 1 Imagery Using Random Forest Algorithm

VANDAM CAESARIADI BRAMDITO*¹, SONY HARTONO WIJAYA¹,
IMAS SUKAESIH SITANGGANG¹

Abstrak

Daerah Istimewa Yogyakarta yang telah ditetapkan sebagai kawasan sentra tebu memerlukan perlakuan khusus dalam upaya ekstensifikasi yang memerlukan informasi spasial usaha tani tebu. Pemantauan lahan tebu dilakukan untuk mendapatkan informasi fase pertumbuhan tebu dan sebarannya untuk strategi ekstensifikasi pertanian. Oleh karena itu perlu dilakukan klasifikasi citra menggunakan algoritma *random forest* yang *reliable* untuk mengklasifikasikan fase pertumbuhan tebu pada citra Sentinel 1 multi-temporal. Peta kalender tanam tebu dibuat dari hasil klasifikasi citra yang telah dilakukan dan menguji tingkat akurasi untuk evaluasi. Klasifikasi dilakukan dengan setiap citra pada setiap bulan yang terekam sepanjang tahun 2020. Data citra yang digunakan sebanyak 9690 sampel piksel yang terdiri atas 6 kelas klasifikasi yaitu bangunan, vegetasi, badan air, sawah, tebu kelas fase 1, dan kelas fase tebu 2. Hasil uji model klasifikasi menunjukkan bahwa Citra Sentinel 1 yang terdiri atas 13 citra memiliki akurasi model rata-rata yaitu 65.38%. Hasil klasifikasi citra yang memiliki tingkat akurasi keseluruhan tertinggi senilai 73.33% dengan nilai RMSE 2.05 terjadi pada bulan Oktober.

Kata Kunci: klasifikasi, pemantauan, *random forest*, Sentinel 1, tebu.

Abstract

The Special Region of Yogyakarta, a designated sugarcane center, demands special attention for effective extensification efforts, necessitating spatial insights into sugarcane farming. Monitoring of sugarcane fields served to obtain information on the growth phases of sugarcane and its distribution for agricultural extensification strategies. For this reason, it is necessary to carry out image classification using the Random Forest reliable algorithm to classify sugarcane growth phases in multi-temporal Sentinel 1 images. The sugarcane planting calendar Map is conducted from the image classification outcomes and then tested for its accuracy for evaluation. The classification process involves analyzing each image captured monthly throughout 2020, with a dataset comprising 9690 sample pixels across six classification classes: buildings, vegetation, water bodies, rice fields, sugarcane phase class 1, and sugarcane phase class 2. The results show that the Sentinel 1 image consisting of 13 images has an average classification model accuracy of 65.38%. Notably, the image classification achieved its pinnacle performance in October, boasting the highest overall accuracy level at 73.33%, accompanied by an RMSE value of 2.05.

Keywords: classification, monitoring, random forest, Sentinel 1, sugarcane.

¹ Departemen Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor, Bogor 16680;

* Penulis Korespondensi: Tel: 0896-6431-2229; Surel: vandamcaesariadi@apps.ipb.ac.id

PENDAHULUAN

Direktur Tanaman Semusim dan Rempah, Direktorat Jenderal Perkebunan Kementerian Pertanian berupaya untuk mewujudkan percepatan program swasembada gula konsumsi nasional di tahun 2021 dengan melakukan ekstensifikasi pertanian yaitu perluasan lahan tebu 10,798 Ha yang terdiri atas perluasan seluas 1000 Ha, rawat ratun 6845 Ha, dan bongkar ratun 3000 Ha (Nasution 2020). Dalam melaksanakan kegiatan tersebut tentunya membutuhkan perencanaan dan informasi, salah satu informasinya dapat diperoleh melalui kegiatan pemantauan lahan tebu di Daerah Istimewa (DI) Yogyakarta dengan luas lahan 6845 Ha (BPS 2019). Monitoring lahan pertanian tebu merupakan upaya memperoleh informasi untuk menghasilkan kebijakan pertanian yang baik, karena kebijakan lahan pertanian yang sesuai dengan kondisi di lapangan adalah kebijakan tepat yang mengantar kepada jalur swasembada pangan (Badan Litbang Pertanian 2018).

Terdapat berbagai data kontinu citra penginderaan jauh yang dapat dimanfaatkan untuk memonitor lahan pertanian. Di China penelitian klasifikasi lahan pertanian telah dilakukan dengan liputan citra tahun 2017-2018 menggunakan dua citra yakni citra Sentinel 1A yang merupakan citra SAR dan Sentinel 2 yang merupakan citra optik (Jiang 2019). Sementara itu, kondisi Indonesia yang merupakan daerah tropis bercurah hujan tinggi menyebabkan frekuensi tutupan awan menjadi relatif lebih sering terjadi ketika perekaman citra dilakukan, maka sensor citra gelombang mikro dapat dimanfaatkan untuk memperoleh data yang kontinu. Sensor citra gelombang mikro akan mengeliminasi tutupan awan yang mungkin terjadi karena panjang gelombang mikro jauh lebih panjang dibanding gelombang tampak.


Algoritma *random forest* dipilih dibandingkan dengan algoritma *deep learning* karena sebelumnya telah diketahui bahwa *random forest* cenderung lebih baik untuk dataset kecil hingga dataset ukuran sedang. Semua data-data atau citra yang diproses untuk penelitian ini masuk dalam kategori himpunan data berukuran sedang sehingga ada kemungkinan besar penggunaan algoritma *deep learning* akan menjadi kurang efektif dan efisien (Ramezan 2021). Oleh karena itu, dengan menggunakan data *multi-temporal* citra radar serta menggunakan teknik klasifikasi citra dengan algoritma *random forest* yang dipilih didapatkan tingkat akurasi yang terbaik hingga mencapai 90.2%. Meski waktu pemrosesan yang lebih lama dibanding algoritma lainnya seperti XGBoost dengan akurasi 89.4% (Jiang 2019).

Rencana pemerintah untuk swasembada gula serta melakukan kontrol terhadap harga gula di pasaran memerlukan strategi. Dalam menentukan strategi peningkatan produksi gula dan arah kebijakan yang benar, informasi untuk ekstensifikasi lahan tebu dibutuhkan. Penelitian ini ditujukan untuk menerapkan algoritma *random forest* untuk klasifikasi fase pertumbuhan lahan tebu dan membuat peta kalender tanam lahan tebu untuk memberikan informasi tersebut.

METODE

Area studi penelitian yaitu Kabupaten Bantul, Sleman, Kulonprogo, Gunung Kidul, dan Kota Yogyakarta. Tepatnya seluruh wilayah DI Yogyakarta yang terlihat pada Gambar 1, dimana DI Yogyakarta adalah wilayah setingkat provinsi yang berbatasan dengan Provinsi Jawa Tengah, disesuaikan dengan wilayah yang ditetapkan sebagai sentra tebu oleh Kementerian Pertanian. Upaya pemantauan tanaman tebu ini dilakukan di wilayah DI Yogyakarta yang juga merupakan wilayah tropis karena secara astronomis, wilayah DI Yogyakarta terletak pada posisi 7°33'-80.12' lintang selatan dan 110°00'-110°50' bujur timur. Posisi geografis DI Yogyakarta berada di bagian tengah pulau Jawa, tepatnya sisi selatan.

Sumber data citra Sentinel 1 berasal dari *European Space Agency* (ESA). *European Space Agency* (ESA) adalah organisasi di Uni Eropa yang menyediakan data citra Sentinel 1 untuk citra radar, data citra Sentinel 2 untuk citra *multispectral*, dan Sentinel 3 untuk citra infra merah termal dan altimetri. Melalui web resmi ESA, pengguna dapat memilih untuk mengunduh data penginderaan jauh yang dibutuhkan, salah satunya citra *Sentinel 1A*.



Gambar 1 Area penelitian Daerah Istimewa Yogyakarta (kiri); citra Sentinel 1 liputan D.I. Yogyakarta (kanan)

Area studi yang dipilih adalah DI Yogyakarta yang merupakan salah satu sentra tebu, dan data citra Sentinel 1 liputan tahun 2020. Lahan tebu DI Yogyakarta tersebar cukup luas meski hanya ukuran petak-petak kecil yang tersebar hampir merata di Kabupaten Sleman, Kulonprogo, Bantul, dan Gunungkidul. DI Yogyakarta memiliki pabrik yang digunakan untuk memproses hasil panen dari lahan tebu yang ada di DI Yogyakarta. Dalam melakukan ekstraksi informasi mengenai lahan tebu DI Yogyakarta, memerlukan informasi spasial dan temporal, dimana data spasial format *Shapefile* diperoleh sebagai data sekunder dari Dinas Perkebunan DI Yogyakarta, kegiatan survei lapangan secara langsung, dan data pendukung serta informasi-informasi yang diperoleh dari proses-proses yang dilakukan.

Citra yang digunakan untuk penelitian ini adalah Citra Sentinel 1 dengan dua polarisasi yakni VV dan VH. Kemudian jumlah citra yang digunakan adalah 13 paket citra terdiri atas 13 citra polarisasi VV dan 13 citra polarisasi VH. Setiap citra mewakili setiap bulan di tahun 2020 kecuali citra bulan Juli yang diwakili 4 citra yakni citra VV 19 Juli 2020, citra VH 19 Juli 2020, citra VV 26 Juli 2020, dan citra VH 26 Juli 2020. Hal ini dikarenakan pada bulan Juli tidak ada *path* atau liputan yang menyeluruh sehingga diwakili dengan 2 paket citra yang berbeda dengan waktu berbeda pada *path* liputan citra yang berbeda juga. Pada prosesnya data latih disiapkan, yang diperoleh dari data sekunder Dinas Perkebunan DI Yogyakarta khusus untuk data latih fase pertumbuhan tebu, kemudian data latih untuk objek non-lahan tebu diperoleh dari hasil interpretasi citra. Data *GIS* diproses menggunakan aplikasi QuantumGIS, dan untuk memproses data Sentinel 1 menggunakan SNAP ESA yang meliputi kegiatan pra-proses dan proses klasifikasi data.

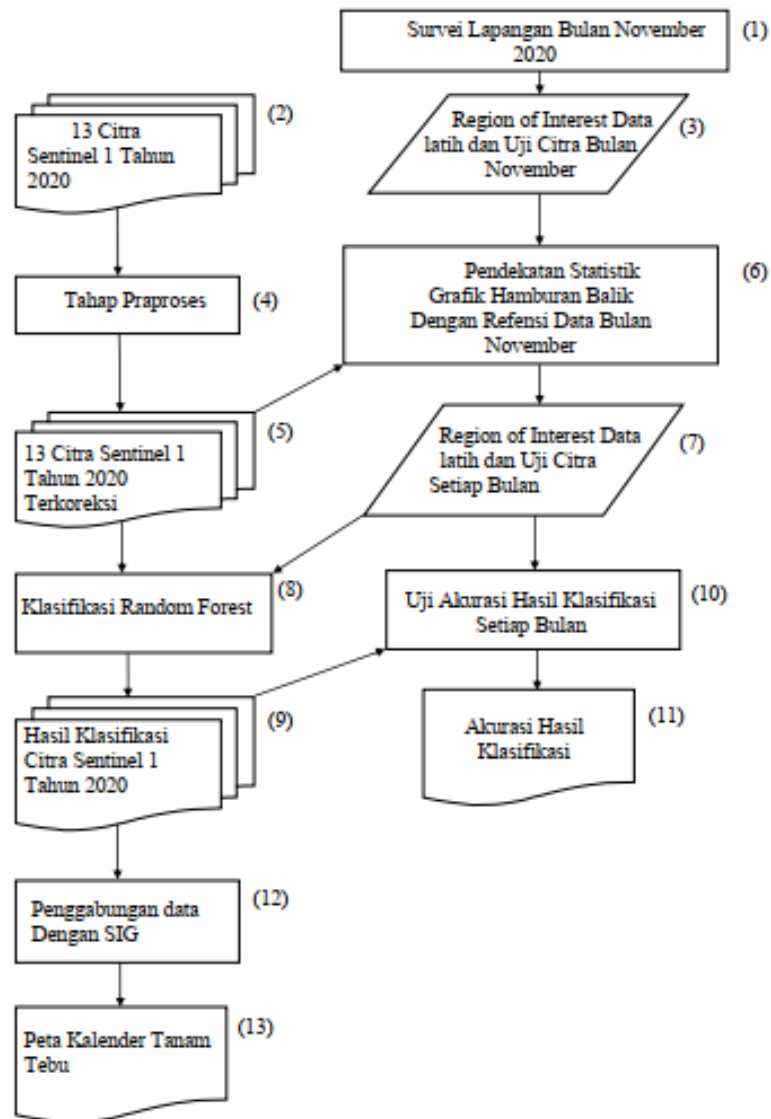
Tahapan Penelitian

Penelitian yang dilakukan melalui beberapa tahapan yaitu pengumpulan data, pra-proses citra satelit yang dilakukan seperti Gambar 3 dengan menggunakan aplikasi SNAP ESA, proses klasifikasi citra satelit, klasifikasi data hamburan balik dari analisis grafik nilai hamburan balik 12 citra untuk setiap bulan, evaluasi hasil klasifikasi citra satelit, penggabungan data hasil klasifikasi dengan sistem informasi geografi dan pembuatan peta kalender tanam tebu. Tahapan yang dilalui dapat dilihat pada Gambar 2 yang deskripsinya di jelaskan dalam 6 langkah, yaitu:


1. Melakukan kegiatan survey ke lapangan pada bulan November 2020 dan mengunduh data 13 citra Sentinel 1 dari ESA yang masuk dalam kategori pengumpulan data.
2. Melakukan kegiatan pra-proses untuk citra dan membuat *region of interest* secara umum dari data survey lapangan.
3. Melakukan pendekatan statistik data nilai hamburan balik untuk mengetahui rentang nilai objek pada citra dan mengelaskannya pada 6 kelas objek untuk membuat *region of interest* atau data latih untuk citra Sentinel 1 setiap bulan pada tahun 2020.
4. Melakukan klasifikasi citra Sentinel 1 *random forest* dengan penetapan 6 kelas.

5. Hasil klasifikasi diuji dengan *confusion matrix* untuk memberikan informasi akurasi keseluruhan klasifikasi citra Sentinel 1 di setiap bulan.
6. Mengekstrak informasi dari citra hasil klasifikasi menggunakan data sekunder area lahan tebu untuk memperoleh informasi fase pertumbuhan tebu setiap bulan untuk membuat peta kalender tanam tebu.

Algoritma *random forest* berperan untuk mengklasifikasikan citra untuk memperoleh informasi spasial obyek penutup lahan dan fase di lahan tebu. Simpulan hasil akhir dari penelitian ini adalah hasil uji akurasi klasifikasi citra Sentinel 1 yang digunakan untuk mengidentifikasi sebaran tebu beserta fase pertumbuhannya dengan bentuk keluaran berupa peta kalender tanam tebu.



Gambar 2 Tahapan penelitian



Gambar 3 Alur tahap praproses citra *raw* data Sentinel 1 dengan aplikasi SNAP

Pra-proses

Hasil perekaman citra Sentinel 1 memiliki kesalahan karena berbagai hal, salah satunya atmosfer. Oleh karena itu diperlukan koreksi citra seperti *thermal noise removal*, kalibrasi, konversi nilai sinyal, *terrain correction*, dan subset yang urutannya dapat dilihat di Gambar 3. Resolusi spasial adalah ukuran objek terkecil di bumi yang mampu dikenali. Resolusi spasial dibatasi ukuran piksel, yang pada penelitian ini berukuran 20×20 m (Filipponi 2019).

Proses Klasifikasi Citra Satelit

1. Ekstraksi nilai DN (*Digital Number*) *band* setiap piksel

Citra SAR tersimpan dalam format *.tif* yang terdiri atas *band* tunggal. Setiap pikselnya akan diperoleh ukuran 20×20 meter yang memuat informasi nilai hamburan balik atau *digital number*.

2. Pembentukan area contoh sebagai data latih

Nilai DN yang merupakan nilai hamburan balik diidentifikasi kenampakannya di lapangan. Nilai-nilai tersebut direkap kemudian dibuat atasan area dengan membuat titik atau poligon yang sesuai dengan data di lapangan untuk membuat data latih dan data uji.

3. Klasifikasi terbimbing menggunakan algoritma *random forest*

Klasifikasi terbimbing (*supervised classification*) dilakukan dengan menetapkan beberapa area contoh sebagai data latih yang mewakili kelas lahan tebu yang ada, kemudian seluruh piksel ditetapkan kelas fase pertumbuhannya berdasarkan area contoh. Prinsip kerjanya adalah membandingkan setiap piksel yang tidak diketahui kelasnya terhadap contoh kelas yang telah dibuat (Solorio-Ramírez 2023).

Evaluasi Hasil Klasifikasi Citra Satelit

Confusion matrix adalah suatu metode untuk menggambarkan performa dari suatu model klasifikasi dengan membandingkan hasil prediksi model dengan nilai sebenarnya dari data yang diamati. *Confusion matrix* biasanya direpresentasikan dalam bentuk tabel dengan dua kolom dan dua baris untuk masalah klasifikasi biner. Namun, untuk masalah klasifikasi dengan lebih dari dua kelas, matriks tersebut memiliki dimensi yang sesuai dengan jumlah kelas yang ada. Kesalahan komisi merupakan suatu area yang diklasifikasikan pada kelas yang salah di lapangan. Jadi n_{wx} , n_{wy} dan seterusnya adalah jumlah kelas-kelas yang diklasifikasikan secara salah di lapangan. Nilai ini menunjukkan seberapa baik suatu piksel terklasifikasi. Kesalahan komisi dirumuskan dengan Persamaan 1 (Markoulidakis 2021).

$$\text{Kesalahan komisi} = \frac{n_{wx} + n_{wy} + n_{wz}}{n_{w+}} \times 100\% \quad (1)$$

Kesalahan omisi adalah kesalahan yang disebabkan suatu area di lapangan tidak diklasifikasikan pada kelas yang benar. Jadi n_{xw} , n_{yw} dan seterusnya adalah jumlah kelas-kelas yang ada di lapangan tidak diklasifikasikan pada kelas yang benar. Nilai ini menunjukkan seberapa baik suatu kelas diklasifikasikan (Markoulidakis 2021). Rumus kesalahan omisi ditunjukkan pada Persamaan 2.

$$\text{Kesalahan omisi} = \frac{n_{xw} + n_{yw} + n_{zw}}{n_{+w}} \times 100\% \quad (2)$$

Akurasi keseluruhan merujuk pada banyak piksel yang terklasifikasi secara benar pada tiap kelas dibandingkan dengan jumlah sampel yang digunakan. Kelemahan akurasi ini yaitu tidak mempertimbangkan aspek kesalahan tiap kelas. Akurasi yang dianjurkan adalah koefisien kappa, karena memperhitungkan semua elemen atau kolom dari *confusion matrix*. Persamaan 3 dan 4 adalah rumus akurasi keseluruhan dan akurasi koefisien kappa (Foody 2002).

$$\text{Akurasi kesalahan} = \frac{\sum_{k=1}^q n_{kk}}{n} \times 100\% \quad (3)$$

$$\text{Kappa} = \frac{n \sum_{k=1}^q n_{kk} - \sum_{k=1}^q n_{k+} \times n_{+k}}{n^2 - n \sum_{k=1}^q n_{k+} \times n_{+k}} \quad (4)$$

n_{kk} adalah nilai diagonal dari matriks kontingensi baris ke- k dan kolom- k , dimana n_{+k} merupakan jumlah piksel dalam kolom ke- k dan n_{k+} jumlah piksel dalam baris ke- k . Kemudian n merupakan piksel dalam contoh.

Pembuatan Peta Kalender Tanam

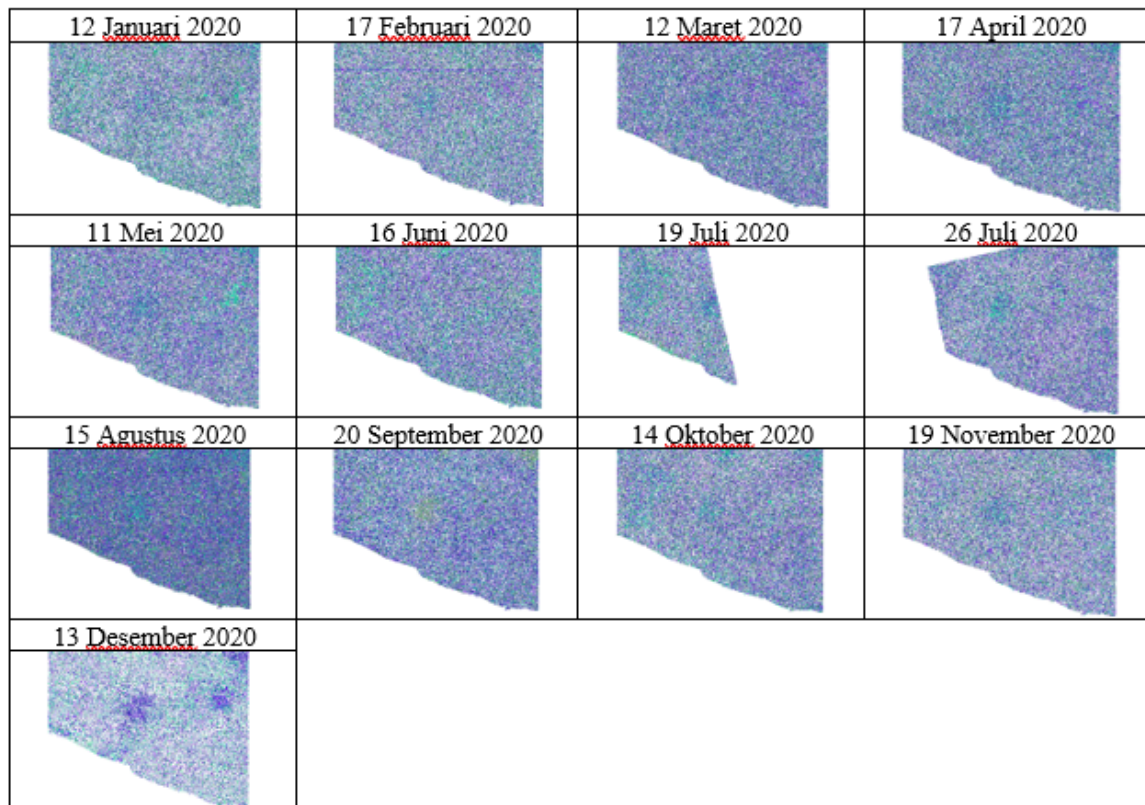
Peta kalender tanam perlu untuk dibuat untuk memberikan gambaran spasial dan temporal distribusi lahan dan fase pertumbuhannya dalam kasus ini lahan tebu. Dibutuhkan data spasial dan data temporal dalam pembuatannya, yang diperoleh dari data sekunder, data hasil kegiatan survei lapangan, dan data informasi dari hasil klasifikasi yang tentunya mempertimbangkan nilai *time series* hamburan balik dari lahan yang terkonfirmasi, yaitu lahan tebu, baik dari data sekunder maupun dikonfirmasi langsung di lapangan (Buhary *et al.* 2018). Data spasial yang dimaksud adalah data spasial lahan tebu dalam format *shapefile* yang merupakan data sekunder dari dinas perkebunan. Nilai hamburan balik citra Sentinel 1 di lahan tebu memberikan informasi spasial dan temporal dari 13 citra Sentinel 1 dan data kegiatan survei dengan GPS memberikan informasi lokasi lahan tebu dan fase pertumbuhannya.

HASIL DAN PEMBAHASAN

Klasifikasi citra telah dilakukan dengan mengimplementasikan algoritma *random forest* pada citra tiap bulan di tahun 2020. Paket data yang digunakan ada 13 citra yang masing-masing memiliki 2 citra dengan polarisasi VH dan VV. Citra hasil klasifikasi pada bulan Juli 2020 diwakilkan oleh 2 data, yaitu citra 19 Juli 2020 dan 26 Juli 2020 dikarenakan tidak ada akuisisi data yang menyeluruh mencakup area kajian penelitian yakni wilayah Daerah Istimewa Yogyakarta, sehingga upaya saling melengkapi data dilakukan terkhusus data bulan Juli 2020.

Implementasi klasifikasi dilakukan dengan menerapkan 6 kelas yang terdiri dari kelas bangunan, vegetasi, lahan terbangun, tubuh air, tebu fase 1, dan tebu fase 2. Pada Gambar 4 dapat dilihat 13 citra hasil klasifikasi. Secara sekilas hasil klasifikasi memiliki *noise* seperti citra radar pada umumnya, meskipun sebelumnya tahap pra-proses yang penting sudah dilakukan untuk menormalisasi data, yaitu dengan menghilangkan *outlier* atau *noise* (Hao 2019). Data *training* dan data *testing* dibuat dengan perbandingan 80:20, 80% sebagai data *training* dan 20% sebagai data *testing*. Proses menghilangkan *outlier* telah dilakukan pada kegiatan pra-proses yang meliputi *thermal noise removal*, *linier calibration*, dan koreksi radiometrik yang secara umum menghilangkan *noise* yang merupakan *outlier* pada citra.

Perbedaan warna pada hasil klasifikasi bukan merupakan hasil perbedaan yang signifikan antar data citra bulan satu dengan bulan lainnya. Melainkan karena penerapan urutan klasifikasi kelas yang berubah untuk berbagai bulan meskipun akurasi untuk setiap bulannya terhadap masing-masing kelas bisa berubah. Seperti pada bulan basah, akurasi kelas tubuh air dan lahan sawah akan sangat buruk karena lahan sawah pada fase pengairan dan *data training* serta algoritma *random forest* belum mampu membedakannya, sehingga pada bulan tertentu tubuh air bisa diklasifikasikan sebagai sawah, dan sawah dikelaskan sebagai tubuh air. Kemudian untuk lahan tebunya, fase pertumbuhan lahan tebu bisa jadi tidak bisa terkelaskan dengan baik karena nilai hamburan balik yang memiliki perbedaan yang tidak signifikan, terutama karena diketahui dari hasil kegiatan survei di lapangan bahwa lahan tebu DI Yogyakarta waktu tanam dan panennya cenderung homogen. Hal ini berbeda jika ditemukan wilayah yang memiliki lahan tebu dengan fase pertumbuhan yang beragam. Wilayah tersebut akan memiliki perbedaan nilai hamburan balik yang signifikan antar kelas.

Gambar 4 Hasil klasifikasi *random forest* pada 13 citra Sentinel 1

Hasil klasifikasi akan diuji akurasi menggunakan tabel *confusion matrix* (Kavats 2020), dimana pada bulan kegiatan survei dilakukan menjadi referensi untuk melakukan uji akurasi. Diketahui bahwa pada Tabel 1, *confusion matrix* pada lahan sawah memiliki nilai akurasi yang terendah dan lahan sawah memiliki perbedaan nilai hamburan balik yang signifikan pada fase tertentu. Hal ini tidak saja menjadi masalah pada citra Sentinel 1 yang merupakan citra radar tetapi juga citra optik, sehingga untuk keperluan aplikasi, klasifikasi penutup lahan untuk kelas sawah juga perlu memperhatikan musim dan fase pertumbuhan, sehingga dalam pengkelasan bisa dikoreksi dengan data dari luar hasil interpretasi atau survei lapangan secara langsung.

Kajian menggunakan *confusion matrix* memberikan gambaran mengenai penelitian tentang klasifikasi citra pada komponen nilai komisi dan omisi, dimana nilai ini memberikan gambaran kesalahan dari klasifikasi citra terhadap objek yang diklasifikasikan. Kesalahan komisi adalah persentase kesalahan suatu objek kelas yang diprediksi tidak sesuai dengan kelas aktual dibagi dengan jumlah prediksi yang benar sesuai kelas objek tersebut. Kesalahan omisi adalah persentase kesalahan suatu objek kelas yang diprediksi tidak sesuai dengan kelas aktual dibagi dengan jumlah kelas aktual tersebut. Sebagaimana terlihat pada Tabel 1 dan Tabel 2, kesalahan komisi ini mengelaskan 20 titik sebagai bangunan, namun yang sebenarnya di lapangan hanya 17, sehingga kesalahan komisinya adalah 15% dan akurasi pembuatnya adalah 85% untuk kelas bangunan. Kemudian untuk kesalahan omisi, hasil klasifikasi ada yang mengelaskan bangunan sebagai vegetasi yang kelas aktualnya adalah bangunan. Jumlah kesalahan ini dibagi jumlah prediksi yang benar terhadap aktual di kelas bangunan sehingga akurasi penggunaannya 94.44% dan kesalahan omisinya 5.56% untuk kelas bangunan. Perihal ini sangat penting dalam studi klasifikasi citra untuk penginderaan jarak jauh karena dapat mengetahui nilai objek kelas dari citra terhadap sifat alami objek secara geografisnya di lapangan.

Akurasi model klasifikasi tertinggi dapat dilihat pada Tabel 3, yaitu 73.33% yang merupakan klasifikasi bulan Oktober dengan *RMSE* 2.05. Nilai bias yang mendekati 0 menunjukkan bahwa model yang dibangun bukanlah model yang sederhana sehingga kompleksitas

dari model tersebut mampu membuat nilai selisih antara rata-rata nilai prediksi dari model *machine learning* yang dibuat dengan nilai rata-rata yang sebenarnya tidak berbeda jauh. Tabel 3 menunjukkan nilai akurasi keseluruhan untuk setiap akuisisi citra hasil klasifikasi. Nilai akurasi terendah yaitu 61.67% yang merupakan akuisisi citra bulan September, dengan nilai akuisisi citra rata-rata 65.38%. Kelas fase pertumbuhan tebu, diketahui ada 2 fase tanam tebu di D.I. Yogyakarta. Informasi ini diperoleh dari kegiatan survei lapangan. Waktu tanam dilakukan pada bulan Agustus bulan Oktober. Fase pertumbuhan kelas yang diterapkan pada klasifikasi citra dengan *random forest* disesuaikan untuk setiap bulannya sesuai perkiraan fase dari grafik nilai hamburan balik. Gambar 5 menunjukkan hasil klasifikasi yang merupakan hasil klasifikasi citra bulan Oktober, menunjukkan gambaran penutup lahan yang sesuai dengan keadaan di lapangan.

Tabel 1 *Confusion matrix*

No	Kelas Prediksi	Kelas Aktual						Σ
		Bangunan	Vegetasi	Tubuh Air	Sawah	Tebu Fase 1	Tebu Fase 2	
1	Bangunan	17	1	0	0	1	1	20
2	Vegetasi	1	15	0	1	1	2	20
3	Tubuh air	0	0	17	3	0	0	20
4	Sawah	0	1	5	12	1	1	20
5	Tebu Fase 1	0	1	1	1	14	3	20
6	Tebu Fase 2	0	1	1	2	2	14	20
	Σ	18	19	24	19	19	21	120

Tabel 2 Nilai akurasi kelas dan *overall accuracy* (bulan Oktober)

No	Kelas	Akurasi Pengguna	Omisi	Akurasi Pembuat	Komisi
1	Bangunan	94,44%	0.05556	85%	0.15
2	Vegetasi	73,68%	0.26315	70%	0.3
3	Tubuh Air	70,83%	0.29167	85%	0.15
4	Sawah	63,15%	0.36842	60%	0.4
5	Tebu Fase 1	73,68%	0.26315	70%	0.3
6	Tebu Fase 2	66,67%	0.33333	70%	0.3
Overall accuracy				73,33%	

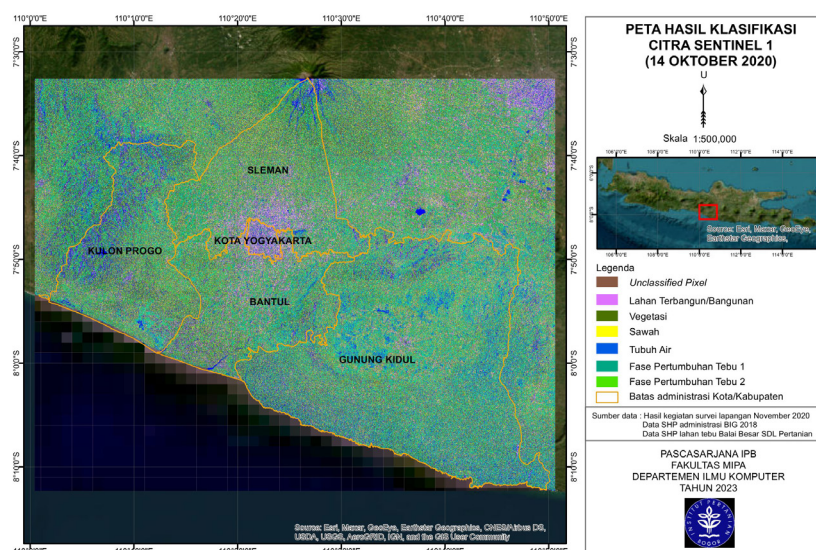
Tabel 3 Nilai *overall accuracy* dari klasifikasi citra setiap bulan

No	Akuisisi Citra	RMSE	BIAS	Overall Accuracy
1	1/12/2020	2.22899	-0.16542	64.16%
2	2/17/2020	2.14629	-0.12205	63.33%
3	3/12/2020	2.06247	-0.13155	70.00%
4	4/17/2020	2.10735	-0.18525	65.83%
5	5/11/2020	2.24137	-0.17947	63.33%
6	6/16/2020	2.10607	-0.05183	70.83%
7	7/19/2020	2.30218	-0.19279	62.50%
8	7/26/2020	2.20401	-0.15592	64.16%
9	8/15/2020	2.30420	-0.08137	63.33%
10	9/20/2020	2.35540	-0.15675	61.67%
11	10/14/2020	2.05746	-0.09603	73.33%
12	11/19/2020	2.29085	-0.23895	62.50%
13	12/13/2020	2.20930	-0.11524	65.00%

Gambar 5 menunjukkan hasil klasifikasi citra bulan Oktober yang dibuat dalam bentuk peta. Kesesuaian citra hasil klasifikasi dengan kondisi aktual untuk kelas-kelas objek yang memiliki perbedaan nilai yang signifikan pada citra terlihat terkelaskan dengan baik seperti objek bangunan dan objek tubuh air. Selain objek tersebut, seperti objek kelas fase tebu, vegetasi, dan sawah memiliki tantangan untuk bisa mengkelaskannya dengan lebih baik. Pada bulan-bulan lain tentu sawah yang masih belum ditanami bisa sangat mungkin terkelaskan sebagai objek lain sebagai tubuh air, vegetasi, atau lahan terbangun berdasarkan nilai hamburan baliknya yang secara umum mirip. Akan tetapi, hasilnya dirasa cukup baik untuk memberikan informasi untuk membuat kalender tanam yang ditunjukkan pada Gambar 7.

Proses klasifikasi melibatkan dua citra, yaitu citra polarisasi VH dan citra polarisasi VV. Dengan melibatkan 2 citra untuk klasifikasi dapat meningkatkan akurasi dan kualitas dari hasil klasifikasi, karena algoritma *random forest* akan mempertimbangkan dua data nilai hamburan balik dalam menentukan kelasnya. Nilai hamburan balik pada polarisasi VV merupakan grafik nilai hamburan balik setiap bulan di tahun 2020. Nilai hamburan balik pada polarisasi VH merupakan grafik nilai setiap bulan di tahun 2020. Secara visual citra VV bisa membandingkan objek yang berbeda dengan lebih kontras, seperti lahan terbangun, tubuh air, vegetasi yang memiliki nilai yang berbeda signifikan, namun pada objek yang sama seperti pengkelasan pada fase pertumbuhan tebu, maka perbedaannya tidak signifikan, sehingga cenderung sulit untuk dibedakan kelasnya. Namun, hal ini bisa dibantu dengan citra polarisasi VH yang memiliki perbedaan nilai hamburan balik yang cukup signifikan untuk setiap objeknya. Pada saat kedua data digunakan untuk keperluan klasifikasi, akan memberikan data yang lebih baik dalam proses mengkelaskan objek. Jika diamati informasi nilai hamburan balik pada citra polarisasi VV terlihat setiap fase pertumbuhan tebu tidak memiliki nilai yang signifikan, namun ketika lahan di fase panen atau awal tanam, dimana lahan berubah menjadi lahan kosong, maka terjadi perubahan nilai yang signifikan. Sesuai dengan hasil wawancara bahwa kegiatan panen atau penanaman dilakukan di bulan 8 atau Agustus dan bulan 10 atau Oktober tahun 2020.

Kegiatan penelitian ini tidak hanya untuk kegiatan penelitian uji akurasi tetapi juga penerapan aplikasi untuk menunjukkan informasi spasial dan temporal mengenai waktu tanam dan fase pertumbuhannya tiap bulan sepanjang tahun. Pada Gambar 6 ditunjukkan bahwa pada peta kalender tanam ini, memuat informasi mengenai distribusi spasial dari lahan tebu di Daerah Istimewa Yogyakarta, juga memuat informasi temporal dari fase pertumbuhan tebu yang digambarkan dibawah peta. Peta ini menggambarkan fase pertumbuhan pada bulan November 2020, sehingga diperkirakan distribusi fase pertumbuhan tebu di bulan lainnya dapat digambarkan berdasarkan informasi temporal tersebut.



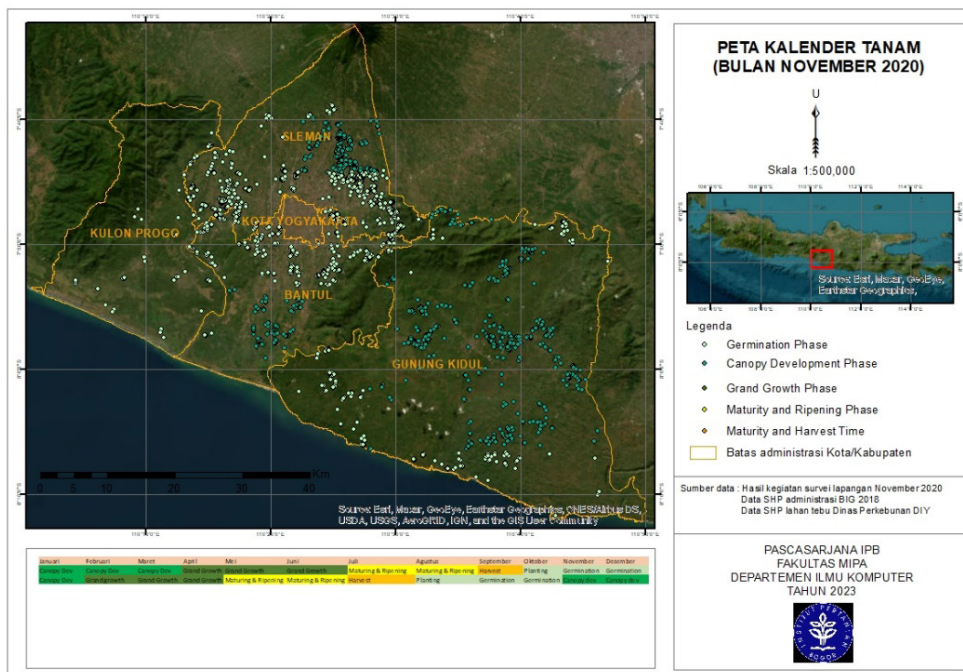
Gambar 5 Peta hasil klasifikasi (bulan Oktober 2020)

Berdasarkan Wakhid (2013), peta kalender tanam memuat informasi spasial dan temporal pada peta. Biasanya peta kalender tanam dibuat dan divisualisasikan dalam bentuk beberapa peta dalam rentang periode tertentu, sehingga jika dibuat dalam satu peta dibutuhkan informasi lain dalam peta untuk merepresentasikan seluruh data. Informasi lain tersebut memberikan gambaran perubahan visualisasi data untuk periode data yang berbeda. Peta pada penelitian ini diberikan informasi berupa warna pada fase pertumbuhan yang terdapat pada wilayah kajian, sehingga dapat diketahui perubahan fase pada titik petak lahan tebu di setiap bulannya. Berdasarkan Runtuwu (2012), peta kalender tanam dibuat dalam bentuk sistem informasi yang memberikan visualisasi yang dinamis, sehingga data-data spasial dan data temporal setiap bulan divisualisasikan secara interaktif. Namun, dalam dokumentasi ilmiah perlu adanya visualisasi yang dapat direpresentasikan dalam bentuk 1 peta, sehingga dibuat peta dengan suatu periode namun dapat memberikan gambaran informasi spasial untuk bulan-bulan lainnya. Seperti yang terlihat pada Gambar 6, yaitu informasi fase pertumbuhan tebu. Diketahui bahwa dari data hasil kegiatan survei lapangan, wawancara, dan informasi dari citra satelit diperoleh informasi fase pertumbuhan tebu. Diketahui bahwa fase pertumbuhan tebu di Yogyakarta ternyata cukup homogen yaitu hanya berselang 2 bulan. Menurut Ramses (2019), fase pertumbuhan tebu yang homogen hanya memiliki 2 fase.

Pada Gambar 7, peta kalender tanam yang dibuat memuat informasi legenda titik, yang melambangkan petak lahan tebu, dan warnanya melambangkan fase pertumbuhannya (Wakhid 2013). Peta kalender tanam yang dibuat berdasarkan data bulan November, dan diketahui fase pertumbuhannya hanya ada dua yakni *germination phase* atau fase kecambah dan *canopy development phase* atau fase vegetatif. Jika dibuat peta untuk bulan Mei maka akan ada dua fase, *grand growth phase* atau fase generatif dan *maturity and ripening phase* atau fase pematangan.

Januari	Februari	Maret	April	Mei	Juni
Canopy Dev	Canopy Dev	Canopy Dev	Grand Growth	Grand Growth	Grand Growth
Canopy Dev	Grand growth	Grand Growth	Grand Growth	Maturing & Ripening	Maturing & Ripening
Juli	Agustus	September	Oktober	November	Desember
Maturing & Ripening	Maturing & Ripening	Harvest	Planting	Germination	Germination
Harvest	Planting	Germination	Germination	Canopy dev	Canopy dev

Gambar 6 Fase pertumbuhan tebu di DI Yogyakarta setiap bulannya



Gambar 7 Peta kalender tanam (bulan November 2020)

SIMPULAN

Model klasifikasi memiliki akurasi keseluruhan rata-rata 65.38% untuk citra semua bulan dan akurasi terbaik jatuh pada citra klasifikasi pada bulan Oktober, dengan tingkat akurasi keseluruhan senilai 73.33%, dengan nilai *RMSE* 2.05. Dari segi kompleksitas, model klasifikasi yang dibangun sudah cukup baik. Namun, akurasi keseluruhan hasil klasifikasi belum mencapai 85% disebabkan salah satunya karena model klasifikasi yang dibuat belum melakukan *hyperparameter tuning*. Jika menerapkan konfigurasi proses klasifikasi dengan *hyperparameter tuning*, kemungkinan nilai akurasi model klasifikasi akan meningkat.

UCAPAN TERIMA KASIH

Terimakasih kepada Dinas Perkebunan D.I. Yogyakarta dan Balai Besar Penelitian Sumberdaya Lahan Pertanian atas kesediannya dalam memberikan data *Shapefile* Lahan Tebu.

DAFTAR PUSTAKA

- [Balitbangtan] Badan Litbang Pertanian. 2018. Sentra Produksi Tebu Tanaman Perkebunan. [diakses 18 Januari 2021] <http://inaagrimap.litbang.pertanian.go.id/index.php/sentra-produksi/tanaman-perkebunan/tebu>.
- [BPS] Badan Pusat Statistik. 2019. Statistik Tebu Indonesia 2018. Jakarta Pusat, Badan Pusat Statistik Republik Indonesia.
- Buhary M. 2018. Peta Kalender Tanam Untuk Tanaman Pangan Di Pulau Jawa. [Diakses 18 Januari 2021]. Tersedia pada :<https://bpatp.litbang.pertanian.go.id/balaipatp/berita/333>.
- Braun A. 2020. Time Series Analysis with Sentinel 1. Ontario, Canada. Skywatch Space Application.
- [ESA] European Space Agency. 2014. Sentinel 1 Mission [abstrak]. Sentinel 1 Overview. [diakses 18 Januari 2021]. Tersedia pada: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>.
- [ESA] European Space Agency. 2017. SNAP – ESA Science Toolbox Exploitation Platform (STEP). Tersedia pada <https://step.esa.int/main/toolboxes/snap/>.
- [ESA] European Space Agency. 2019. *SNAP: Sentinel Application Platform. The Netherlands (NL): ESA Communications*.
- Filipponi F. 2019. Sentinel 1 GRD Preprocessing Workflow. Basel, Switzerland. MDPI Proceeding. 18(1).
- Jiang *et al.* 2019. Early Season Mapping of Sugarcane by Applying Machine Learning Algorithms to Sentinel-1A/2 Time Series Data: A Case Study in Zhanjiang City, China. Basel, Switzerland. MDPI Remote Sensing Journal. 11(7).
- Kavats O, *et al.* 2020. *Monitoring of Sugarcane Harvest in Brazil Based on Optical and SAR Data*. Basel, Switzerland. MDPI Remote Sensing Journal. 12(8).
- Markoulidakis, I., Kopsiaftis, G., Rallis, I. and Georgoulas, I., 2021. Multi-class confusion matrix reduction method and its application on net promoter score classification problem. In *The 14th pervasive technologies related to assistive environments conference* (pp. 412-419).
- Nasution DD. 2020. Pemerintah Targetkan Swasembada Gula Konsumsi tahun 2023. <https://www.republika.co.id/berita/qkagf2370/pemerintahtargetkanswasembada-gula-konsumsi-pada-2023>. [Diakses 8 Maret 2021].
- Ramezan, C.A., Warner, T.A., Maxwell, A.E. and Price, B.S., 2021. Effects of training set size on supervised machine-learning land-cover classification of large-area high-resolution remotely sensed data. *Remote Sensing*. 13(3): 368.
- Runtuwu E, *et al.* 2012. Sistem Informasi Kalender Tanam Terpadu: Status Terkini dan Tantangan Masa Depan. Bogor. IAARD *E Journal*. Jurnal Sumberdaya Lahan. 6(2).

- Solorio-Ramírez, J.L., Jiménez-Cruz, R., Villuendas-Rey, Y. and Yáñez-Márquez, C. 2023. Random forest Algorithm for the Classification of Spectral Data of Astronomical Objects. *Algorithms*. 16(6): 293.
- Wakhid, N. Haris S. Izhar Kairullah. 2013. Peta Kalender Tanam Padi Pada Lahan Rawa Lebak di Kalimantan Selatan di Tengah Perubahan Iklim Global. Bogor. Badan Informasi Geospasial Jurnal ilmiah Geomatika. 19(1).
- Zhang, L. and Wang, S., 2017. Region-of-interest extraction based on local–global contrast analysis and intra-spectrum information distribution estimation for remote sensing images. *Remote Sensing*. 9(6): 597.