

MODEL KLASIFIKASI UNTUK PREDIKSI FASE PERTUMBUHAN PADI DENGAN MACHINE LEARNING BERDASARKAN CITRA SATELIT

(Classification Model for Paddy Growth Phase Prediction with Machine Learning Based on Satellite Imagery)

Novian Tamara¹, Aji Hamim Wigena², Bagus Sartono²

¹Badan Pusat Statistik Kabupaten Serang

²Institut Pertanian Bogor

Jl. Kaserangan - Pengampelan No.7, Kaserangan, Kec. Ciruas, Serang, Banten

E-mail: novian.tamara@bps.go.id

Diterima: 9 Februari 2021; Direvisi: 26 September 2021; Disetujui untuk Dipublikasikan: 15 Oktober 2021

ABSTRAK

Padi memegang peranan penting bagi masyarakat Indonesia. Rumah Tangga Usaha Pertanian (RTUP) padi sebesar 64,85% dari RTUP sub sektor tanaman pangan tahun 2018. Data padi yang akurat dapat membantu pemerintah dalam menyusun perencanaan, mengeksekusi program, dan membuat keputusan yang tepat. Tujuan penelitian kami yaitu membangun model klasifikasi untuk prediksi fase pertumbuhan padi sebagai upaya dalam mendukung keakuratan data padi. Pemodelan multi kelas dilakukan dengan teknik *machine learning* yaitu *Random Forest* dan *Support Vector Machine*. Penelitian ini menggunakan citra Landsat-8 dan Sentinel-2 sebagai fitur yang disupervisi oleh data Kerangka Sampling Area (KSA) dari BPS sebagai variabel target. Sebanyak 1239 fitur statistik temporal turunan dari 18 indeks spektral Sentinel-2 dan 15 indeks spektral Landsat-8 diseleksi dengan plot korelasi dan teknik *stepwise*. Ketidakeimbangan data ditangani dengan teknik sampling SMOTE+TL. Pada klasifikasi tahap 1, performa model dalam memprediksi sawah padi, sawah bukan padi, dan bukan sawah mencapai akurasi 0,95 dan *Matthews Correlation Coefficient* (MCC) 0,84. Pada klasifikasi tahap 2, performa model dalam memprediksi fase pertumbuhan padi mencapai akurasi 0,87 dan MCC 0,73. Hasil menunjukkan kombinasi citra Landsat-8 dan Sentinel-2, seleksi fitur temporal, serta pemilihan metode klasifikasi mampu meningkatkan performa model.

Kata kunci: Fitur statistik temporal, kerangka sampel area, klasifikasi fase pertumbuhan padi

ABSTRACT

Paddy plays an important role in Indonesian society. Paddy agricultural business households amounted to 64.85% of the food crops sub-sector RTUP in 2018. Accurate paddy data can assist the government in planning, executing programs, and formulating the right decisions. Our research aimed to build a classification model for predicting the paddy growth phase to support paddy data accuracy. Multi-class modeling was carried out using machine learning techniques: Random Forest and Support Vector Machine. This research used Landsat-8 and Sentinel-2 imagery data as features that were supervised by Area Sampling Frame (ASF) data from Statistics Indonesia as the target variable. A total of 1239 temporal statistical features derived from 18 spectral indices of Sentinel-2 and 15 spectral indices of Landsat-8 were selected using correlation plots and stepwise techniques. Data imbalance was handled by the SMOTE + TL sampling technique. In classification stage 1, the performance of the model in predicting paddy, non-paddy, and non-crop fields reaches an accuracy of 0.95 and Matthews Correlation Coefficient (MCC) of 0.84. In classification stage 2, the model performance in predicting the phase of rice growth reached an accuracy of 0.87 and MCC of 0.73. The results show that the combination of Landsat-8 and Sentinel-2 imagery, the selection of temporal features, and the selection of machine learning methods could improved model performance.

Keywords: Temporal statistical features, area sampling frame, paddy growth phase classification

PENDAHULUAN

Padi tidak diragukan lagi peranannya bagi masyarakat Indonesia. Rumah Tangga Usaha Pertanian (RTUP) padi tahun 2018 sebesar 64,85% dari RTUP sub sektor tanaman pangan (BPS 2018). Persentase tersebut yaitu sekitar tiga belas ribu rumah tangga. Apabila data padi akurat, pemerintah dapat menyusun perencanaan yang benar seperti meningkatkan kesediaan beras dan memperluas

lahan sawah. Pemerintah dapat mengeksekusi program yang tepat sasaran misalnya distribusi bibit dan pupuk bersubsidi yang tidak berlebihan atau kekurangan. Pemerintah mampu membuat keputusan yang tepat seperti kebijakan alih fungsi lahan dan pengendalian impor beras. Sejak tahun 2018 data padi yang dikeluarkan oleh Badan Pusat Statistik (BPS) semakin akurat dengan metode Kerangka Sampel Area (KSA).

Ada beberapa informasi terkait survei KSA di kabupaten Serang. Pertama, ukuran sampel KSA padi di kabupaten ini 1,6% dari luas sawah baku. Kedua, masih memungkinkan terdapat *noise* pada label di data KSA. *Noise* ini dapat terjadi ketika pencacah salah mengategorikan status lahan pada saat *ground check* dan terlewat terkoreksi oleh pengawas. Ketiga, titik sampel dapat tidak terdata di antaranya yaitu ketika petugas tidak dapat mengunjungi titik sampel misalnya karena banjir, gangguan transmisi data pada saat *upload*, atau petugas melewati batas waktu pencacahan.

Triscowati (2019) membuat model klasifikasi multikelas fase pertumbuhan padi di Kabupaten Banyuwangi dengan fitur *original band* dan 4 indeks spektral dari citra Landsat-8 yang disupervisi oleh data KSA menggunakan metode *Random Forest*. Labelnya terdiri atas 9 kelas yaitu vegetatif awal, vegetatif akhir, generatif, panen, persiapan lahan/bera, puso, sawah bukan padi, bukan sawah, dan generatif akhir. Akurasi modelnya secara keseluruhan yaitu 73,64% pada 1 tahap klasifikasi dan 75,5% pada 2 tahap klasifikasi. Pada tahun 2020 modelnya dikembangkan menjadi KSA-Hybrid. Ketika terjadi pandemi Covid-19 yang berakibat kegiatan survei KSA dihentikan sementara, model KSA-Hybrid dapat digunakan untuk mengamati titik sampel KSA (Khasanah et al. 2020).

Wijayanto et al, (2020) telah mengidentifikasi lahan jagung di Provinsi Jawa Timur dengan teknik *Random Forest*. Labelnya adalah data KSA jagung tahun 2019 dan variabel targetnya adalah berbagai kombinasi citra Sentinel-1, Sentinel-2, Landsat-8. Hasilnya menunjukkan bahwa model dengan variabel target kombinasi Landsat-8 dan Sentinel-2 sebagai yang terbaik. Akurasinya mencapai 79,03% dengan kappa sebesar 58,44%. Performa model turun ketika Sentinel-1 digunakan sebagai variabel target baik secara individu maupun kombinasi dengan dua citra lainnya.

Penelitian ini bertujuan membentuk model klasifikasi terbaik untuk prediksi fase pertumbuhan padi dengan fitur berbasis citra satelit Landsat-8 dan Sentinel-2. Kedua citra tersebut populer dalam studi pemetaan tutupan lahan serta dapat diunduh secara gratis di *Google Earth Engine* (GEE). Penelitian ini menggunakan 18 jenis indeks spektral yang diturunkan dari *original band* citra satelit. Indeks spektral tersebut terpilih karena kemampuannya dalam melihat berbagai sifat vegetasi tanaman, deteksi air, dan fitur buatan manusia.

Penelitian ini menggunakan metode klasifikasi *Random Forest* dan *Support Vector Machine* (SVM). Survei menunjukkan bahwa kedua metode tersebut populer dan berperforma unggul pada studi pemetaan tanaman (Sheykhmousa et al. 2020). Data label KSA memiliki distribusi kelas yang tidak seimbang. Ketidakseimbangan kelas pada data ditangani dengan teknik SMOTE+TL. Teknik tersebut mengguguli 14 teknik sampling lainnya pada data dengan kelas tidak seimbang (Santos et

al. 2018). Proses seleksi fitur juga dilakukan agar model tidak *overfitting* (Ying 2019).

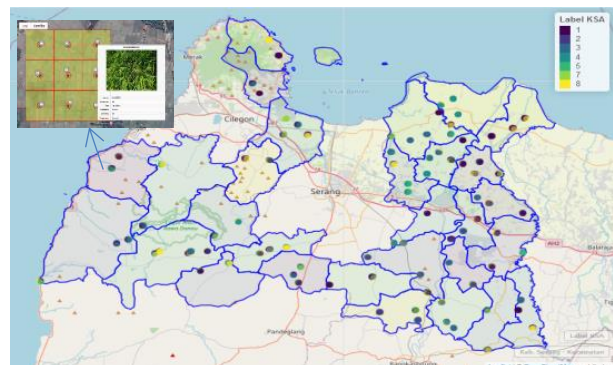
Proses klasifikasi dibagi menjadi dua tahap. Klasifikasi tahap 1 untuk identifikasi sawah padi. Klasifikasi ini memiliki 3 kelas yaitu sawah padi, sawah bukan padi, dan bukan sawah. Klasifikasi tahap 2 untuk mengklasifikasikan fase pertumbuhan padi. Klasifikasi ini memiliki 6 kelas yaitu vegetatif awal, vegetatif akhir, generatif, panen, persiapan lahan, dan puso. Proses seleksi fitur pada 2 tahap klasifikasi saling bebas sehingga memungkinkan model klasifikasi tahap 1 dan tahap 2 memiliki fitur yang berbeda.

Penelitian ini menggunakan data label yang bersumber dari survei KSA padi Kabupaten Serang. Hal tersebut dikarenakan kabupaten tersebut merupakan sentra padi di Provinsi Banten selain Kabupaten Pandeglang. Di wilayah tersebut, pengawasan secara langsung survei KSA padi telah dilakukan oleh peneliti dari tahun 2017 hingga 2018. Oleh karena itu, peneliti telah memahami permasalahan di lapangan terkait survei, memahami karakteristik wilayah seperti iklim dan jenis padi, dan deteksi adanya *noise* data KSA.


METODE

Lokasi dan Data

Data label bersumber dari survei KSA padi Badan Pusat Statistik di Kabupaten Serang periode Januari 2018 sampai Desember 2018. **Gambar 1** menunjukkan lokasi titik sampel KSA padi Kabupaten Serang dimana petugas BPS mendatangi dan mengamati status lahan secara langsung tanpa wawancara. Label terdiri dari 8 kelas yaitu vegetatif awal (VA), vegetatif akhir (VR), generatif (G), panen (P), persiapan lahan (PL), puso (PS), sawah bukan padi (BP), dan bukan sawah (BS). Data label memiliki kelas tidak seimbang yang dapat dilihat pada **Gambar 2**. Ketidakseimbangan tersebut ditangani dengan SMOTE+TL.



Gambar 1. Peta lokasi sampel KSA padi Kab. Serang.



Gambar 2. Distribusi label kelas data KSA padi Kabupaten Serang tahun 2018.

Definisi dari 8 kelas tersebut sebagai berikut. Vegetatif awal adalah fase pertumbuhan padi dimulai dari awal tanam sampai anakan maksimum (1-35 hari setelah tanam). Vegetatif akhir adalah fase pertumbuhan padi dimulai dari anakan maksimum sampai sebelum keluar malai (35-55 hari setelah tanam). Generatif adalah fase pertumbuhan padi dimulai dari keluar malai, pematangan, sampai sebelum panen (55-105 hari setelah tanam). Panen adalah fase pertumbuhan padi saat sedang atau sudah dipanen. Persiapan lahan adalah fase dimana lahan sawah mulai diolah untuk persiapan tanam padi. Puso adalah apabila terjadi serangan OPT (Organisme Pengganggu Tumbuhan) atau bencana, sehingga produksi padi kurang dari 11% dari normal. Sawah bukan padi adalah areal persawahan yang dibudidayakan untuk tanaman selain padi. Bukan sawah adalah apabila titik pengamatan jatuh pada areal bukan persawahan, misalnya hutan, pemukiman, jalan (BPS, 2019).

Data fitur bersumber dari citra Landsat-8 SR dan Sentinel-2 TOA. *Original band* dari kedua citra tersebut ditransformasi menjadi indeks spektral. Indeks spektral yang digunakan dalam penelitian yaitu *Enchanted Vegetation Index* (EVI), *Normalized Difference Vegetation Index* (NDVI), *Visible Atmospherically Resistant Index* (VARI), *Chlorophyll Index – Green* (CIg), *Carotenoid Reflectance Index 1* (CRI1), *Structure Intensive Pigment Index* (SIPI), *Water Body Index* (WBI), *Global Vegetation Moisture Index* (GVMI), *Normalized Difference Water Index* (NDWI), *Normalized Difference Tillage Index* (NDTI), *Normalized Difference Infrared Index* (NDII), *Photosynthetic Vigour Ratio* (PVR), *Rice Growth Vegetation Index* (RGVI), *Built-up Area Index* (BAI), *Weighted Difference Vegetation Index* (WDVI) yang diturunkan dari Landsat-8 dan Sentinel-2 serta *Modified Triangular Vegetation Index 2* (MTVI2), *MERIS Terrestrial Chlorophyll Index* (MTCI), *Moisture Stress Index* (MSI) yang diturunkan dari Sentinel-2. Ada 15 indeks spektral dari Landsat-8 dan 18 indeks spektral dari Sentinel-2 yang diujicobakan. Formula dari masing-masing indeks

spektral dapat dilihat pada referensi yang terdapat pada **Tabel 1**.

Tabel 1. Indeks spektral dan referensinya.

No.	Indeks Spektral	Referensi	Deteksi
1	EVI	(Huete et al., 1997)	kehijauan, indeks luas daun
2	NDVI	(Rouse et al., 1973)	kehijauan, indeks luas daun
3	VARI	(Gitelson et al., 2002a)	kehijauan, indeks luas daun
4	MTVI2	(Haboudane et al., 2004)	kehijauan, indeks luas daun
5	WDVI	(Clevers, 1991)	kehijauan, indeks luas daun
6	CIg	(Gitelson et al., 2003)	konsentrasi klorofil
7	CRI1	(Gitelson et al., 2002b)	konsentrasi klorofil
8	MTCI	(Dash & Curran, 2004)	konsentrasi karetenoid
9	SIPI	(Penuelas et al., 1995)	rasio karetenoid-klorofil
10	WBI	(Domenech & Mallet, 2014)	air
11	GVMI	(Ceccato et al., 2002)	air
12	NDWI	(McFeeters, 1996)	air
13	NDTI	(van Deventer et al., 1997)	residu
14	MSI	(Huntjr & Rock, 1989)	stress tanaman
15	NDII	(Hardisky et al., 1983)	stress tanaman
16	PVR	(Metternicht, 2003)	stress tanaman
17	RGVI	(Nuarsa et al., 2010)	umur padi
18	BAI	(Mhangara et al., 2011)	fitur buatan manusia

Sekumpulan indeks spektral tersebut dilakukan *feature engineering* dengan cara diagregasi berdasarkan 38 jenis statistik temporal yang terdapat pada **Tabel 2**. Simbol x adalah suatu nilai indeks spektral dan t adalah bulan. Dengan menggunakan 38 jenis agregasi, satu jenis indeks spektral akan terbentuk 38 fitur. Dari 18 indeks spektral Sentinel 2 terbentuk fitur sebanyak 18×38 . Resolusi temporal Landsat-8 yang 16 hari mengakibatkan agregasi ragam satu bulan ($S_{x_t}^2$) di citra ini tidak dilakukan karena data tidak tercukupi. Oleh karena itu, jenis agregasi yang dapat digunakan berkurang satu dari 38 menjadi 37. Dari 15 indeks spektral Landsat-8 terbentuk fitur sebanyak 15×37 . Total fiturnya yaitu 1239.

Tabel 2. Pembentukan fitur dari 38 jenis agregasi berdasarkan statistik temporal.

Rataan1	Rataan2	Selisih	Ragam	Median	Minimal	Maksimal	Rentang
1. \bar{x}_t			14. $S_{x_t}^2$	19. Med x_t	24. Min x_t	29. Max x_t	34. Rx_t
2. \bar{x}_{t-1}	6. \bar{x}_{2t}	10. $\Delta\bar{x}_{t,t-1}$	15. $S_{x_{2t}}^2$	20. Med x_{2t}	25. Min x_{2t}	30. Max x_{2t}	35. Rx_{2t}
3. \bar{x}_{t-2}	7. \bar{x}_{3t}	11. $\Delta\bar{x}_{t,t-2}$	16. $S_{x_{3t}}^2$	21. Med x_{3t}	26. Min x_{3t}	31. Max x_{3t}	36. Rx_{3t}
4. \bar{x}_{t-3}	8. \bar{x}_{4t}	12. $\Delta\bar{x}_{t,t-3}$	17. $S_{x_{4t}}^2$	22. Med x_{4t}	27. Min x_{4t}	32. Max x_{4t}	37. Rx_{4t}
5. \bar{x}_{t-4}	9. \bar{x}_{5t}	13. $\Delta\bar{x}_{t,t-4}$	18. $S_{x_{5t}}^2$	23. Med x_{5t}	28. Min x_{5t}	33. Max x_{5t}	38. Rx_{5t}

SMOTE dan Tomek Links

Salah satu metode sampling *hybrid* yang cukup populer yaitu kombinasi *Synthetic Minority Oversampling Technique* dan *Tomek links* (SMOTE+TL). Cara kerjanya adalah dengan melakukan *oversampling* secara SMOTE yang kemudian dilanjutkan *undersampling* dengan metode *Tomek links*. Secara sederhana, algoritma SMOTE menciptakan sampel sintesis dari kelas minoritas berdasarkan kemiripan *feature space* kelas tersebut. *Tomek links* (tautan kembar) disebut demikian jika sepasang sampel yang berbeda kelas merupakan tetangga terdekat satu sama lain. *Undersampling* dapat dilakukan dengan menghapus pasangan sampel tersebut maupun hanya menghapus sampel kelas mayoritas atau minoritas yang merupakan bagian dari *Tomek links*. Hingga saat ini, metode gabungan ini mampu bersaing dengan berbagai metode sampling lainnya dalam meningkatkan performa *classifier* pada masalah kelas tak seimbang (Santos et al., 2018).

Random Forest

Random Forest merupakan modifikasi dari metode *bootstrap aggregating (bagging)* dengan tambahan adanya *random feature selection* (Breiman, 2001). Metode ini dapat digunakan untuk regresi maupun klasifikasi karena merupakan turunan dari metode *classification and regression tree* (CART). *Random Forest* dapat bekerja meski terdapat data *missing*. Metode ini juga mampu mengetahui seberapa penting variabel dalam pengambilan keputusan. *Random feature selection* pada *Random Forest* menjamin pohon tidak berkorelasi sehingga mengurangi kecenderungan *overfitting*. Secara default *software* R menetapkan $a_n = n$, $n_{tree} = 500$, $m_{try} = d/3$ dimana d adalah jumlah fitur, $nodesize = 1$, $maxnodes = null$ (tidak ada).

Support Vector Machine

Support Vector Machine (SVM) merupakan salah satu metode dalam *supervised learning* yang dapat digunakan untuk klasifikasi dan regresi. Pada klasifikasi, ide dasar dari *Support Vector Machine* adalah menemukan *hyperplane* dengan *margin* yang maksimal pada *feature space* sebagai pemisah antara dua kelas. *Hyperplane* dengan kriteria tersebut memiliki kapabilitas generalisasi

terbaik yang akan memberikan kemungkinan terkecil terjadi kesalahan klasifikasi. SVM mampu untuk memisahkan data yang tidak dapat dipisahkan secara linier dengan memperluas *feature space* menggunakan *kernel trick* (Karatzoglou et al., 2005). Kernel yang digunakan dalam penelitian ini adalah kernel radial.

Pengukuran Performa Model Klasifikasi

Matthews Correlation Coefficient (MCC) handal dalam mengukur performa model klasifikasi. Jurman et al. (2012) mengkaji dan menyimpulkan bahwa MCC lebih baik dari akurasi dan *confusion entropy* (CEN). Kelebihan MCC yaitu kemampuan diskriminasi yang baik dalam membedakan *confusion matrix* yang mirip, perilaku yang koheren atau konsisten dengan jumlah kelas maupun jumlah sampel yang bervariasi, serta bekerja baik meskipun kelas memiliki ukuran yang sangat berbeda. Ukuran performa lain yang digunakan yaitu *Overall accuracy* dan *balanced accuracy* seperti dapat dilihat pada **Persamaan 1**, **Persamaan 2**, **Persamaan 3** dan **Persamaan 4**. (Carrillo et al. 2014).

$$\begin{aligned}
 \text{accuracy} &= \frac{\text{true positive} + \text{true negative}}{\text{all observation}} \dots\dots\dots 1 \\
 \text{sensitivitas} &= \frac{\text{true positive}}{\text{all positive}} \dots\dots\dots 2 \\
 \text{spesifisitas} &= \frac{\text{true negative}}{\text{all negative}} \dots\dots\dots 3 \\
 \text{bal. accuracy} &= \frac{\text{sensitivitas} + \text{spesifisitas}}{2} \dots\dots\dots 4
 \end{aligned}$$

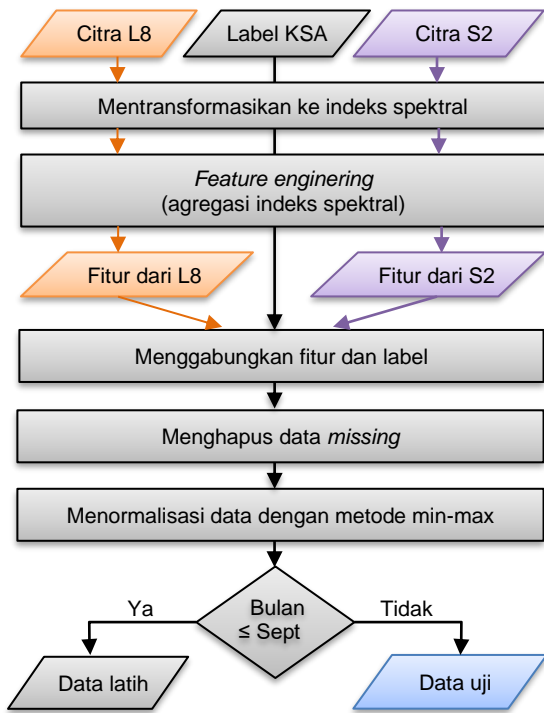
Prapengolahan Data

Tahapan prapengolahan data dapat dilihat pada **Gambar 3**. Tahapan dimulai dengan menyiapkan data KSA, citra Landsat-8 dan citra Sentinel-2. Hasil proses prapengolahan data menghasilkan data yang telah siap digunakan untuk pemodelan dan pengujian.

Eksplorasi Data

Eksplorasi pertama yaitu membandingkan distribusi label kelas data latih dan data uji. Tujuannya adalah untuk melihat kesamaan distribusi kelas antara keduanya dan bagaimana pola ketidakseimbangan data tersebut. Eksplorasi kedua adalah menghitung korelasi antar indeks spektral pada data latih. Tujuan dari eksplorasi kedua adalah sebagai gambaran awal untuk

mengelompokkan indeks spektral yang saling berkorelasi kuat.



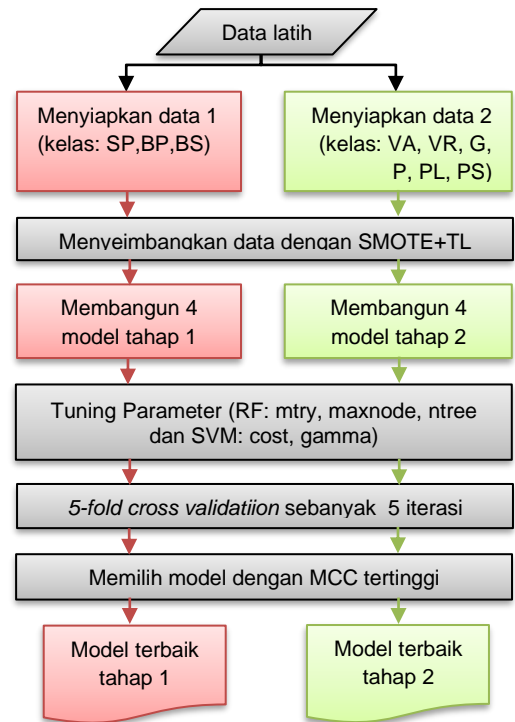
Gambar 3. Tahapan prapengolahan data.

Seleksi Fitur

Seleksi fitur diawali dengan memilih jenis agregasi yang terbaik dengan membandingkan 1239 model berfitur tunggal menggunakan metode *Random Forest*. Metode tersebut mudah diaplikasikan tanpa perlu tuning parameter. Langkah selanjutnya, memilih kombinasi fitur yang memaksimalkan nilai MCC model dengan teknik *backward* dan *forward stepwise*. Indeks spektral pembentuk fitur tersebut harus tidak saling berkorelasi kuat untuk mencegah *overfitting*. Model divalidasi menggunakan *5-fold cross validation* sebanyak 5 iterasi pada seluruh tahapan seleksi.

Pemodelan dan Pengujian

Pemodelan menggunakan data latih dengan tahapan yang terdapat pada Gambar 4. Pada proses penyeimbangan data teknik SMOTE, seluruh kelas disamakan jumlah datanya dengan mengacu ke kelas mayoritas. Pada teknik TL, yang terhapus adalah kelas yang lebih mayoritas. Proses pembangunan 4 model mengacu ke Tabel 3.



Gambar 4. Tahapan pemodelan.

Tabel 3. Spesifikasi Model Klasifikasi.

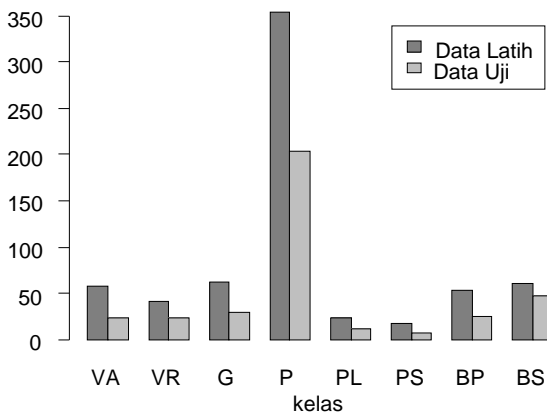
Model	Citra	Metode
RFL8	Landsat-8	<i>Random Forest</i>
RFL8S2	Landsat-8 dan Sentinel-2	<i>Random Forest</i>
SVML8	Landsat-8	SVM
SVML8S2	Landsat-8 dan Sentinel-2	SVM

Tahapan pengujian model terdiri atas dua bagian. Pengujian pertama, menguji model terbaik tahap 1 dengan data uji dalam mengidentifikasi sawah padi. Bagian kedua, jika hasil model tahap 1 adalah benar sawah padi maka data sawah padi tersebut digunakan untuk menguji model terbaik tahap 2 dalam menduga fase pertumbuhan padi.

HASIL DAN PEMBAHASAN

Eksplorasi Data


Distribusi label kelas data latih dan data uji menunjukkan kemiripan pola distribusi jumlah data pada masing-masing kelas. Jumlah data uji berkisar setengahnya dari jumlah data latih di hampir seluruh kelas. Kelas panen merupakan kelas mayoritas sedangkan persiapan lahan dan puso adalah yang paling sedikit jumlah datanya. Selengkapnya dapat dilihat pada Gambar 5.




Gambar 5. Distribusi label kelas data latih dan data uji hasil prapengolahan.

Eksplorasi terhadap ada tidaknya korelasi antar indeks spektral penting untuk dilakukan. Fitur dibentuk dari agregasi indeks spektral. Beberapa algoritma *machine learning* tidak dapat menangani dengan baik masalah fitur yang saling berkorelasi kuat satu sama lain (sesama fitur dan bukan dengan variabel target). Model yang dilatih dari sekumpulan data yang terdapat multikolinieritas tidak akan menjadi yang terbaik. Masalah multikolinieritas menjadi salah satu penyebab *overfitting* pada model. Pada data dengan jumlah sampel yang relatif sedikit dan jumlah fitur yang relatif banyak, salah satu cara menghindari *overfitting* adalah dengan tidak menggunakan seluruh ribuan fitur tersebut melainkan memilih fitur yang berguna dan menghapus fitur yang kurang berguna (Ying 2019).

Eksplorasi terhadap data latih menunjukkan beberapa indeks spektral saling berkorelasi kuat ($r \geq 0,75$). Contohnya yaitu ada pada **Gambar 6**. Ada pula beberapa indeks spektral yang tidak saling berkorelasi kuat satu sama lainnya. Contohnya yaitu ada pada **Gambar 7**.



Gambar 6. Contoh korelasi kuat indeks spektral citra Landsat-8.



Gambar 7. Contoh korelasi tidak kuat indeks spektral berbasis citra Landsat-8.


Korelasi antar indeks spektral dengan basis citra satelit yang berbeda tidak dihitung karena kedua satelit tersebut sudah independen (jenis dan spesifikasi sensornya sudah berbeda). Secara ringkas, **Tabel 4** menyajikan pengelompokan indeks spektral berdasarkan nilai korelasi (r) baik berbasis citra Landsat-8 maupun Sentinel-2.

Tabel 4. Kelompok korelasi indeks spektral Landsat-8 (L8) dan Sentinel-2 (S2).

Kelompok	$r \geq 0,75$	Indeks Spektral
K1_L8	Ya	NDVI, VARI, WDVI, Clg, NDWI, PVR, BAI
K2_L8	Ya	GVMi, NDII
K3_L8	Tidak	EVI, CRI1, SIPI, WBI, NDTI, RGVI
K1_S2	Ya	EVI, NDVI, WDVI, Clg, MTVI2, MTCI, NDWI, BAI
K2_S2	Ya	VARI, WBI, GVMi, MSI, NDII, PVR
K3_S2	Tidak	CRI1, SIPI, NDTI, RGVI

Seleksi Fitur Klasifikasi Tahap 1

Proses seleksi fitur diawali dengan mencari jenis agregasi yang mampu mendiferensiasi kelas sawah padi, sawah bukan padi, dan bukan sawah dengan baik. Sejumlah 1239 fitur tercipta dari proses *feature engineering*. Proses ini mengagregasikan indeks spektral berdasarkan 38 jenis agregasi. Setiap satu fitur dibentuk satu model dengan metode *Random Forest* sehingga tercipta 1239 model berfitur tunggal. Perbandingan nilai MCC dari seluruh model tersebut yang dikelompokkan berdasarkan jenis agregasinya dapat dilihat pada **Gambar 8**. Absisnya mengacu pada **Tabel 2**.



Gambar 8. Perbandingan nilai MCC model berfitur tunggal klasifikasi tahap 1 yang terkelompok dalam 38 jenis agregasi.

Model berfitur tunggal dari kelompok statistik temporal $Min x_{5t}$ dan $Max x_{5t}$ adalah yang memiliki median nilai MCC tertinggi. Artinya mayoritas indeks spektral dengan agregasi minimal dan maksimal pada periode 5 bulan ($Max x_{5t}$ dan $Min x_{5t}$) adalah yang paling baik dibandingkan 36 jenis agregasi lainnya. Oleh karena itu, fitur pada model tahap 1 dibangun dengan agregasi $Max x_{5t}$ dan $Min x_{5t}$. Berdasarkan teknik stepwise dengan metode *Random Forest*, indeks spektral terpilih untuk model tahap 1 tersedia pada **Tabel 5**. Seluruh indeks spektral yang terpilih tidak saling berkorelasi kuat.

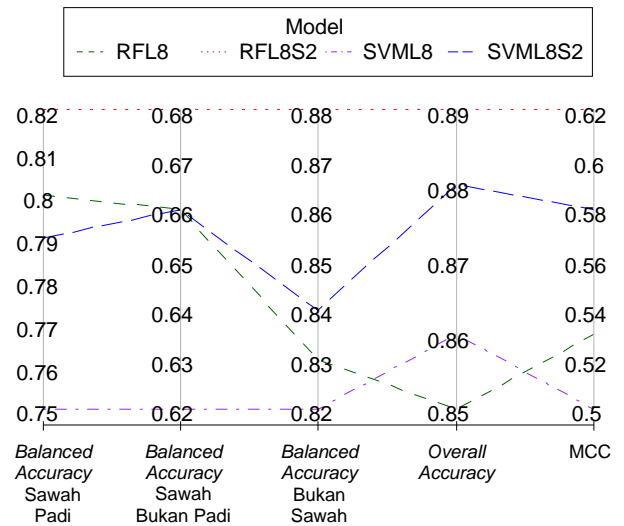
Tabel 5. Indeks spektral terpilih model tahap 1.

Citra	Indeks Spektral
Landsat-8	WDVI, GVMI, NDTI, RGVI, WBI
Sentinel-2	WDVI, GVMI, NDTI, RGVI

Total fitur terpilih untuk model klasifikasi tahap 1 berjumlah 18. Sejumlah 10 fitur dibentuk dari lima indeks spektral berbasis Landsat-8 yang diagregasi berdasarkan $Max x_{5t}$ dan $Min x_{5t}$. Sejumlah 8 fitur dibentuk dari empat indeks spektral berbasis Sentinel-2 yang diagregasi berdasarkan $Max x_{5t}$ dan $Min x_{5t}$. Fitur yang terseleksi berjumlah sedikit menunjukkan bahwa lebih baik menggunakan sedikit fitur namun informatif daripada ribuan fitur yang mubazir.

Seleksi Model Klasifikasi Tahap 1

Pemodelan klasifikasi tahap 1 untuk membedakan sawah padi, sawah bukan padi, dan bukan sawah dibangun ke dalam 4 model berdasarkan spesifikasi model pada Error! Reference source not found.. Parameter modelnya yaitu RFL8 (*default*), RFL8S2 (*default*), SVML8 (*cost* 1,5; *gamma* 0,8; kernel radial), dan SVML8S2 (*cost* 5,5; *gamma* 0,12; kernel radial) yang merupakan hasil dari tuning parameter. Perbandingan performa keempat model berdasarkan *5-fold cross validation* 5 iterasi dapat dilihat pada **Gambar 9**.



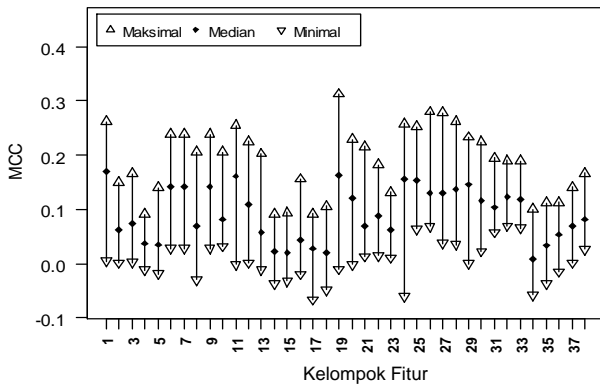
Gambar 9. Perbandingan performa model tahap 1.

Model RFL8S2 mengungguli seluruh model lainnya dengan nilai MCC tertinggi sebesar 0,62. Oleh karena itu, model RFL8S2 terpilih sebagai model terbaik klasifikasi tahap 1. MCC dipilih sebagai kriteria model terbaik karena semakin tinggi nilai MCC semakin tinggi korelasi data kategorik antara matriks prediksi dan matriks aktual. *Overall accuracy* dari model ini adalah yang tertinggi sebesar 0,89. Kelas bukan sawah paling mudah dibedakan dengan *balanced accuracy* tertinggi sebesar 0,88.

Metode dan data citra mana yang lebih baik untuk pemodelan klasifikasi tahap 1 dapat diketahui dari **Gambar 9**. Model dengan fitur berbasis kombinasi citra Landsat-8 dan Sentinel-2 mengungguli model yang hanya dibangun dengan citra Landsat-8 saja baik ketika sama-sama menggunakan metode *Random Forest* maupun SVM. Penambahan fitur berbasis citra Sentinel-2 ke model tahap 1 dengan fitur berbasis Landsat-8 meningkatkan nilai MCC sebesar 9% ketika metodenya *Random Forest* dan 8% ketika metodenya SVM. Sementara itu, metode terbaik pada pemodelan tahap 1 adalah *Random Forest*. Model dengan metode *Random Forest* mengungguli SVM ketika fitur yang digunakan sama. Hal tersebut dapat dilihat dari model RFL8 yang mengungguli SVML8 dan model RFL8S2 yang mengungguli SVML8S2.

Seleksi Fitur Klasifikasi Tahap 2

Seleksi fitur klasifikasi tahap 2 memiliki kesamaan proses dengan tahap 1. Sejumlah 1239 model berfitur tunggal dibangun menggunakan metode *Random Forest* dengan parameter *default*. Nilai MCC dari seluruh model tersebut dikelompokkan berdasarkan 38 jenis agregasi yang dapat dilihat pada **Gambar 10** di mana absisnya mengacu pada **Tabel 2**.



Gambar 10. Perbandingan nilai MCC model berfitur tunggal klasifikasi tahap 2 yang terkelompok dalam 38 jenis agregasi.

Pada klasifikasi tahap 2, cukup sulit untuk memilih jenis agregasi terbaik dibandingkan pada tahap 1. Pada kelompok model berfitur tunggal yang dibentuk dari jenis agregasi rentang (R) memiliki pola naik seiring bertambahnya periode t sedangkan lainnya tidak berpola naik atau turun. Meskipun berpola naik, nilai MCC-nya masih di bawah 0,2. Jika dilihat berdasarkan median nilai MCC maka jenis agregasi ke-1 (\bar{x}_t) dan ke-19 (Med x_t) adalah dua yang terbaik diantara jenis agregasi lainnya. Berbagai fitur diciptakan dari dua jenis agregasi tersebut namun belum juga mendapatkan model dengan performa yang baik. Nilai MCC-nya di bawah 0,5. Oleh sebab itu, fitur yang diciptakan tidak berpatokan dengan dua jenis agregasi tersebut saja namun menambah jenis agregasi lainnya yang dilakukan secara *stepwise*.

Hasil akhir dari seleksi fitur secara *stepwise* pada klasifikasi tahap 2 adalah terpilihnya 49 fitur. Fitur tersebut dibangun dari indeks spektral terpilih yang dapat dilihat di **Tabel 6** yang diagregasikan dengan 7 jenis agregasi yaitu \bar{x}_t ; \bar{x}_{t-1} ; \bar{x}_{t-2} ; \bar{x}_{t-3} ; \bar{x}_{t-4} ; Min x_{4t} ; Max x_{3t} . Sejumlah 28 fitur dibentuk dari empat indeks spektral berbasis Landsat-8 yang diagregasi berdasarkan 7 jenis agregasi. Sejumlah 21 fitur dibentuk dari empat indeks spektral berbasis Sentinel-2 yang diagregasi berdasarkan 7 jenis agregasi.


Tabel 6. Indeks spektral terpilih model tahap 2.

Citra	Indeks Spektral
Landsat-8	WDVI, GVMI, NDVI, WBI
Sentinel-2	WDVI, NDII, BAI

Terpilihnya jenis agregasi \bar{x}_t ; \bar{x}_{t-1} ; \bar{x}_{t-2} ; \bar{x}_{t-3} ; \bar{x}_{t-4} menunjukkan bahwa model klasifikasi fase pertumbuhan padi memiliki performa yang lebih baik ketika ada tambahan informasi bulan lalu secara berturut turut hingga empat bulan sebelumnya. Secara awam, seseorang tentu akan lebih akurat dalam menduga fase pertumbuhan suatu tanaman dengan adanya tambahan informasi kondisi masa lalunya. Di samping jenis agregasi tersebut, terpilih juga jenis agregasi Min x_{4t} dan Max x_{3t} yang dapat meningkatkan performa model klasifikasi tahap 2. Jenis agregasi lainnya tidak terpilih karena tidak meningkatkan nilai MCC model.

Seleksi Model Klasifikasi Tahap 2

Model tahap 2 bertujuan untuk mengklasifikasikan fase pertumbuhan padi (vegetatif awal, vegetatif akhir, generatif, panen, persiapan lahan, dan puso). Sama halnya seperti pada tahap 1, empat model klasifikasi yang dibangun dengan spesifikasi yang berbeda dibandingkan performanya. Parameter masing-masing modelnya yaitu yaitu RFL8 (*default*), RFL8S2 (*default*), SVML8 (*cost* 1,4; *gamma* 0,01; kernel radial), dan SVML8S2 (*cost* 3; *gamma* 0,007; kernel radial). Berdasarkan *5-fold cross validation* sebanyak 5 iterasi, performa dari 4 model tersebut dapat dilihat pada **Gambar 11**.



Gambar 11. Perbandingan performa model tahap 2.

Pada klasifikasi tahap 2, model RFL8S2 mengungguli model lainnya. Jika model diurutkan berdasarkan nilai MCC atau *overall accuracy* dari yang tertinggi ke terendah maka peringkatnya yaitu RFL8S2, SVML8S2, RFL8, dan SVML8. Model RFL8S2 memiliki nilai MCC sebesar 0,61 dan *overall accuracy* sebesar 0,77. Berdasarkan nilai *balanced accuracy* dari masing-masing kelas, model RFL8S2 unggul di empat kelas. Oleh karena itu, model RFL8S2 terpilih sebagai model terbaik klasifikasi tahap 2.

Baik dengan metode *Random Forest* maupun SVM, model tahap 2 akan lebih baik jika fitur yang digunakan berbasis kombinasi citra Landsat-8 dan Sentinel-2 daripada berbasis citra Landsat-8 saja. Penambahan fitur berbasis citra Sentinel-2 ke model tahap 2 dengan fitur berbasis Landsat-8 meningkatkan nilai MCC sebesar 6%. baik ketika metodenya *Random Forest* maupun SVM. Berdasarkan ukuran performa selain MCC juga menguatkan kesimpulan tersebut. Model dengan fitur kombinasi tersebut juga unggul dari segi *overall accuracy* serta *balanced accuracy* di 4 kelas dibandingkan yang hanya menggunakan Landsat-8 saja.

Sama seperti pada klasifikasi tahap 1, metode yang lebih baik pada klasifikasi tahap 2 adalah *Random Forest*. Berdasarkan *overall accuracy* dan MCC, model yang menggunakan metode *Random*

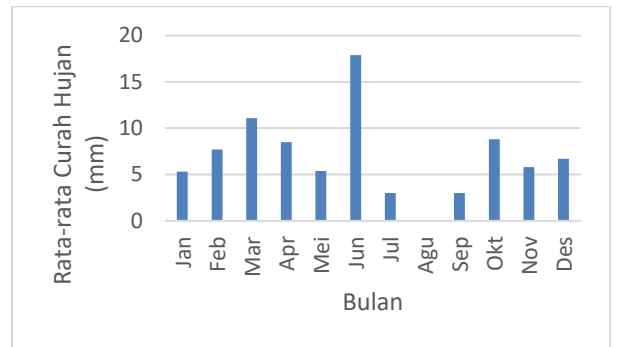
Forest lebih baik daripada SVM ketika fitur yang digunakan sama. Model dengan metode *Random Forest* memiliki *balanced accuracy* pada 4 kelas (vegetatif awal, vegetatif akhir, generatif, dan panen) yang lebih baik. Kelebihan model dengan metode SVM hanya satu yaitu sedikit lebih baik dalam membedakan kelas puso dengan *balanced accuracy* sebesar 0,65. Namun demikian, angka tersebut masih kurang tinggi (tidak memuaskan).

Ada beberapa analisis penyebab mengapa seluruh model kurang baik dalam membedakan kelas puso dan persiapan lahan. Pertama, puso dan persiapan lahan memiliki jumlah sampel yang sangat kecil. Jumlah sampel kelas tersebut jangan terlalu sedikit agar model *machine learning* mampu menggeneralisasi suatu kelas dengan baik. Sedikitnya sampel di kelas tersebut dapat dilihat pada **Gambar 5**. Idealnya jumlah sampel terbaik untuk masing-masing kelas adalah jumlah seluruh observasi dibagi dengan jumlah kelasnya. Jika kondisi ideal tersebut sulit untuk dipenuhi maka jumlah sampel minimal untuk puso dan persiapan lahan yaitu sekitar dua kali lipatnya dari jumlah sampel yang tersedia saat ini di kelas tersebut. Kedua, bentuk areal lahan puso karena kekeringan dan pascapanen (di mana pascapanen masuk dalam kelas panen) secara kasat mata memang mirip. Ini yang menyebabkan puso diprediksi ke kelas panen. Sebagai contoh foto di lapangan, kemiripannya dapat dilihat pada **Gambar 12**.



Gambar 12. (a) Puso; (b) Pascapanen.

Untuk wilayah Kabupaten Serang, puso sebagian besar terjadi karena kekeringan. Soewandita (2018) menyebutkan adanya potensi tingkat kekeringan kelas tinggi di area seluas 1311 ha pada 11 kecamatan dari total 29 kecamatan di kabupaten ini. Penyebabnya adalah jenis tanah yang mudah kering, terbatasnya suplai air irigasi, dan curah hujan yang rendah. Pengamatan secara langsung dan informasi dari petugas survei KSA menunjukkan bahwa sebagian besar puso di kabupaten ini pada tahun tersebut memang karena kekeringan meskipun ada juga yang disebabkan oleh banjir dan serangan hama. Berdasarkan data BMKG, rata-rata curah hujan bulanan Kab. Serang sepanjang tahun 2018 sangat rendah di bawah 20mm seperti tampak pada **Gambar 12**. Curah hujan yang sangat rendah tersebut menyebabkan kekeringan terutama pada areal sawah tadah hujan sehingga menyebabkan puso.



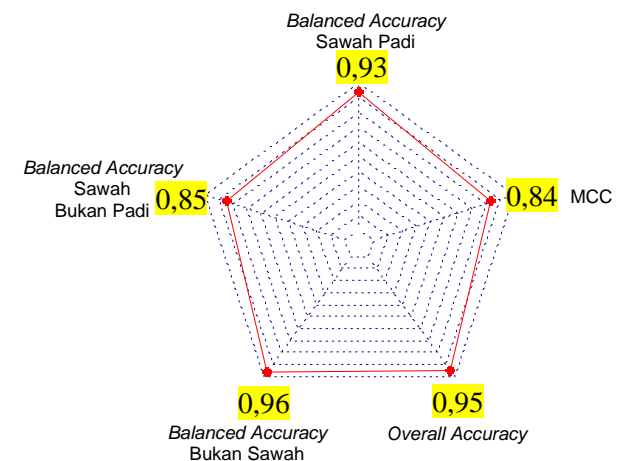
Gambar 13. Rata-rata Curah Hujan Per Bulan di Kabupaten Serang Tahun 2018

Hasil Pengujian

Data uji menggunakan 371 sampel KSA dari bulan Oktober sampai dengan Desember 2018 dengan fitur terisi lengkap (tidak ada data *missing*). Data tersebut digunakan untuk menguji model terbaik tahap 1 RFL8S2 dalam mengidentifikasi lahan sawah padi, sawah bukan padi, dan bukan sawah. Model terbaik tahap 1 tersebut dibangun dari data latih bulan Januari sampai dengan September 2018. *Confusion matrix* dan statistik performa hasil pengujian tertera pada **Tabel 7** dan **Gambar 14**.

Tabel 7. *Confusion matrix* klasifikasi tahap 1 data uji.

Prediksi \ Aktual	Aktual		
	Sawah Padi	Sawah Bukan Padi	Bukan Sawah
Sawah Padi	289	5	2
Sawah Bukan Padi	5	18	1
Bukan Sawah	5	2	44



Gambar 14. Statistik performa model RFL8S2 pada klasifikasi tahap 1 data uji.


Hasil pengujian model tahap 1 RFL8S2 untuk klasifikasi sawah padi, sawah bukan padi, dan bukan sawah memberikan performa yang sudah baik. Model ini tidak mengalami kesulitan dalam memprediksi kelas bukan sawah dengan *balanced accuracy* sebesar 0,96. Sawah padi juga dapat diprediksi dengan baik dengan *balanced accuracy* 0,93. Secara keseluruhan, model RFL8S2 tahap 1

mampu memberikan performa baik pada data uji dengan *overall accuracy* mencapai 0,95 dan MCC 0,84. Pada akurasi tersebut, model dapat menduga dengan benar 95% data uji sesuai aktual kelasnya.

Sejumlah 289 sawah padi yang berhasil teridentifikasi dengan benar dari hasil prediksi model tahap 1 digunakan untuk menguji model tahap 2 RFL8S2. Hasil prediksi model tersebut setelah dibandingkan dengan aktual kelasnya berupa *confusion matrix* dapat dilihat pada **Tabel 8**. Statistik performa dari model ini meliputi nilai MCC, *overall accuracy*, dan *balanced accuracy* dapat dilihat pada **Gambar 15**.

Tabel 8. *Confusion matrix* klasifikasi tahap 1 data uji.

Prediksi \ Aktual						
	VA	VR	G	P	PL	PS
VA	18	2	0	3	1	0
VR	1	16	3	0	0	0
G	0	2	25	0	0	0
P	4	2	1	190	9	5
PL	1	0	1	1	1	0
PS	0	0	0	2	0	1



Gambar 15. Statistik performa model RFL8S2 pada klasifikasi tahap 2 data uji.

Hasil pengujian model tahap 2 dalam mengklasifikasikan fase pertumbuhan padi dapat dikatakan baik. *Overall accuracy* mencapai 0,87 dengan nilai MCC sebesar 0,73. Fase vegetatif awal, vegetatif akhir, generatif, dan panen dapat diprediksi seacara baik dengan *balanced accuracy* di atas 0,85. Berbanding terbalik, persiapan lahan dan puso gagal diprediksi dengan *balanced accuracy* di bawah 0,6.

Model dua tahap RFL8S2 dapat dipertimbangkan untuk prediksi data KSA yang hilang maupun titik lain di luar sampel KSA. Sebanyak 313 dari 371 data yang terdiri dari 8 kelas (kelas asli survei KSA) dapat diprediksi dengan benar sesuai kelasnya berdasarkan teknik klasifikasi hierarki. Dari hasil pengujian tersebut, model 2 tahap RFL8S2 memiliki akurasi global sebesar 0,84. Model 2 tahap ini dapat digunakan untuk klasifikasi penutup lahan karena akurasi yang diperkenankan LAPAN (2015) adalah rata-rata di

atas 0,75. Model 2 tahap tersebut secara global memiliki performa di atas model yang telah dibangun oleh Triscowati (2019). Meskipun demikian, model RFL8S2 belum diuji performanya dalam menduga nilai amatan KSA Kabupaten Banyuwangi seperti yang digunakan oleh Triscowati dalam penelitiannya.

KESIMPULAN

Model terbaik tahap 1 untuk identifikasi padi dan tahap 2 untuk klasifikasi fase pertumbuhan padi adalah model RFL8S2. Metode *Random Forest* lebih baik dari SVM pada 2 tahap klasifikasi tersebut. Penambahan fitur berbasis citra Sentinel-2 ke model klasifikasi fase pertumbuhan padi dengan fitur berbasis Landsat-8 meningkatkan nilai MCC sebesar 6%. Fitur terpilih pada klasifikasi tahap 1 berjumlah 18 sedangkan pada klasifikasi tahap 2 berjumlah 49.

Model RFL8S2 tahap 1 dengan fitur tersebut teruji memiliki akurasi sebesar 0,95 dan MCC sebesar 0,84. Model RFL8S2 tahap 2 dengan fitur tersebut teruji memiliki akurasi 0,87 dan MCC 0,73. Model 2 tahap ini dapat mendeteksi sebagian besar kelas dengan baik. Namun, model tersebut kurang tepat dalam menduga kelas persiapan lahan dan puso. Model dua tahap klasifikasi tersebut secara hierarki dapat menduga 8 kelas nilai amatan KSA dengan akurasi global sebesar 0,84 sehingga model ini dapat dipertimbangkan untuk menduga nilai amatan pada sampel KSA yang tidak terdata. Secara umum, model yang disupervisi oleh data KSA tersebut mampu mengidentifikasi sawah padi dan menduga fase pertumbuhannya dengan data citra satelit Landsat-8 dan Sentinel-2.

UCAPAN TERIMA KASIH

Kami ucapkan terima kasih kepada BPS sebagai penyedia data, Nadya Dwi Muchisha dan Dwi Triscowati sebagai rekan diskusi dalam penelitian ini, serta Tim Redaksi Jurnal Majalah Ilmiah Globe dan Mitra Bestari.

DAFTAR PUSTAKA

[BPS] Badan Pusat Statistik. (2018). *Hasil Survei Pertanian Antar Sensus (SUTAS) 2018*. Jakarta (ID): BPS.

[BPS] Badan Pusat Statistik. (2019). *Buku Pedoman Teknis Pendataan Statistik Pertanian Tanaman Terintegrasi dengan Metode Kerangka Sampel Area untuk Komoditas Padi 2019*. Jakarta (ID): BPS.

Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>

Carrillo, H., Brodersen, K. H., & Castellanos, J. (2014). Probabilistic Performance Evaluation for Multiclass Classification Using the Posterior Balanced Accuracy. *Advances in Intelligent Systems and Computing*, 252, 347–361. https://doi.org/10.1007/978-3-319-03413-3_25

- Ceccato, P., Gobron, N., Flasse, S., Pinty, B., & Tarantola, S. (2002). Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1. *Remote Sensing of Environment*, 82(2–3), 188–197. [https://doi.org/10.1016/S0034-4257\(02\)00037-8](https://doi.org/10.1016/S0034-4257(02)00037-8)
- Clevers, J. G. P. W. (1991). Application of the WDVl in estimating LAI at the generative stage of barley. *ISPRS Journal of Photogrammetry and Remote Sensing*, 46(1), 37–47. [https://doi.org/10.1016/0924-2716\(91\)90005-G](https://doi.org/10.1016/0924-2716(91)90005-G)
- Dash, J., & Curran, P. J. (2004). The MERIS Terrestrial Chlorophyll Index. *International Journal of Remote Sensing*, 25(23), 5403–5413. <https://doi.org/10.1080/0143116042000274015>
- Domenech, E., & Mallet, C. (2014). Change Detection in High-Resolution Land Use/Land Cover Geodatabases (At Object Level). *European Spatial Data Research*, 9–63.
- Gitelson, A. A., Gritz †, Y., & Merzlyak, M. N. (2003). Relationships Between Leaf Chlorophyll Content and Spectral Reflectance and Algorithms for Non-Destructive Chlorophyll Assessment in Higher Plant Leaves. *Journal of Plant Physiology*, 160(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002a). Novel Algorithms for Remote Estimation of Vegetation Fraction. *Remote Sensing of Environment*, (Natural Resources), 76–87.
- Gitelson, A. A., Zur, Y., Chivkunova, O. B., & Merzlyak, M. N. (2002b). Assessing Carotenoid Content in Plant Leaves With Reflectance Spectroscopy. *Photochemistry and Photobiology*, 75(3), 272–281. [https://doi.org/10.1562/0031-8655\(2002\)075<0272:accipl>2.0.co;2](https://doi.org/10.1562/0031-8655(2002)075<0272:accipl>2.0.co;2)
- Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J., & Strachan, I. B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3), 337–352. <https://doi.org/10.1016/j.rse.2003.12.013>
- Hardisky, M. A., Klemas, V., & Smart, R. M. (1983). The Influence of Soil Salinity, Growth Form, and Leaf Moisture on the Spectral Radiance of *Spartina Alterniflora* Canopies. *Photogrammetric Engineering and Remote Sensing*, 49, 77–83.
- Huete, A. R., Liu, H. Q., Batchily, K., & Leeuwen, W. van. (1997). A Comparison of Vegetation Indices Over A Global Set of TM Images for EOS-MODIS. *Remote Sensing of Environment*, 59(3), 440–451. [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)
- Huntjr, E., & Rock, B. (1989). Detection of Changes in Leaf Water Content Using Near- and Middle-Infrared Reflectances☆. *Remote Sensing of Environment*, 30(1), 43–54. [https://doi.org/10.1016/0034-4257\(89\)90046-1](https://doi.org/10.1016/0034-4257(89)90046-1)
- Jurman, G., Riccadonna, S., & Furlanello, C. (2012). A Comparison of MCC and CEN Error Measures in Multi-Class Prediction. *PLoS ONE*, 7(8), e41882. <https://doi.org/10.1371/journal.pone.0041882>
- Karatzoglou, A., Meyer, D., & Hornik, K. (2005). Support Vector Machines in R. *Journal of Statistical Software*, 15, 1–28.
- Khasanah, I. N., Triscowati, D. W., Handoyo, A., Buana, W. P., & Kadir, K. (2020). Kombinasi Survei Kerangka Sampel Area dan Remote Sensing untuk Estimasi Luas Tanaman Padi Di Masa Pandemi (KSA-Hybrid). *Jurnal Aplikasi Statistika & Komputasi Statistik*, 12(2), 53. <https://doi.org/10.34123/jurnalasks.v12i2.284>
- [LAPAN] Lembaga Penerbangan dan Antariksa Nasional. (2015). *Pedoman Pengolahan Data Satelit Multispektral secara Digital Supervised untuk Klasifikasi*. Jakarta (ID): LAPAN.
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the Delineation of Open Water Features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
- Metternicht, G. (2003). Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*, 24(14), 2855–2877. <https://doi.org/10.1080/01431160210163074>
- Mhangara, P., Kleyn, L., Remas, H., & Odindi, J. (2011). Road Extraction Using Object Oriented Classification. *PositionIT*, 45–50.
- Nuarsa, I. W., Nishio, F., & Hongo, C. (2010). Development of the Empirical Model for Rice Field Distribution Mapping Using Multi-Temporal Landsat ETM+ Data: Case Study in Bali Indonesia. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 38, 482–487.
- Penuelas, J., Frederic, I., & Filella. (1995). Semi-Empirical Indices to Assess Carotenoids/Chlorophyll-a Ratio from Leaf Spectral Reflectance. *Photosynthetica*, 3, 221–230.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring Vegetation Systems in the Great Plains with ERTS. *Proceedings of 3rd Earth Resources Technology Satellite Symposium*, 1, 309–317. Washington, DC: NASA.
- Santos, M. S., Soares, J. P., Abreu, P. H., Araujo, H., & Santos, J. (2018a). Cross-Validation for Imbalanced Datasets: Avoiding Overoptimistic and Overfitting Approaches [Research Frontier]. *IEEE Computational Intelligence Magazine*, 13(4), 59–76. <https://doi.org/10.1109/MCI.2018.2866730>
- Santos, M. S., Soares, J. P., Abreu, P. H., Araujo, H., & Santos, J. (2018b). Cross-Validation for Imbalanced Datasets: Avoiding Overoptimistic and Overfitting Approaches [Research Frontier]. *IEEE Computational Intelligence Magazine*, 13(4), 59–76. <https://doi.org/10.1109/MCI.2018.2866730>
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308–6325. <https://doi.org/10.1109/JSTARS.2020.3026724>
- Soewardita, H. (2018). Analisis Bencana Kekeringan Di Wilayah Kabupaten Serang. *Jurnal Sains Dan Teknologi Mitigasi Bencana*, 13, 34–43.
- Triscowati, D. W. (2019). *Klasifikasi Fase Pertumbuhan Padi Menggunakan Random Forest Berdasarkan Data Multitemporal Landsat-8 [tesis]*. Institut Pertanian Bogor, Bogor (ID).
- van Deventer, A. P., Ward, A. D., Gowda, P. H., & Lyon, J. G. (1997). Using Thematic Mapper Data to Identify Contrasting Soil Plains and Tillage Practices. *Photogrammetric Engineering & Remote Sensing*, 63, 87–93.
- Wijayanto, A. W., Triscowati, D. W., & Marsuhandi, A. H. (2020). Maize field area detection in East Java, Indonesia: An integrated multispectral remote

sensing and machine learning approach. *2020 12th International Conference on Information Technology and Electrical Engineering (ICITEE)*, 168–173. <https://doi.org/10.1109/ICITEE49829.2020.9271683>

Ying, X. (2019). An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*, 1168, 022022. <https://doi.org/10.1088/1742-6596/1168/2/022022>