

## Pemetaan Lahan Pertanian Padi Berbasis Machine Learning untuk Mendukung Ketahanan Pangan Kabupaten Soppeng

M Afdal<sup>\*1</sup>, Mayang Sari<sup>2</sup>

<sup>1,2</sup> Program Studi Sistem Informasi, Universitas Lamappapoleonro

<sup>1,2</sup>Jl. Kesatria No.60 Watansoppeng, Soppeng Sulawesi Selatan

Email: <sup>\*1</sup>afdal@unipol.ac.id, <sup>2</sup>mayang291@gmail.com

(Naskah masuk: 23-08-2025, direvisi: 17-09-2025, diterbitkan: 30-11-2025)

### Abstrak

Penelitian ini mengembangkan pendekatan pemetaan lahan padi berbasis *machine learning* untuk memperkuat perencanaan ketahanan pangan di Kabupaten Soppeng. Studi memanfaatkan citra satelit resolusi menengah, indeks vegetasi *time-series*, dan fitur spasial-temporal (curah hujan, elevasi, tekstur spektral) guna mengklasifikasikan tutupan lahan padi serta memetakan dinamika luas tanam dan pola musim. Model utama membandingkan algoritma terawasi (*Random Forest, SVM*) dan arsitektur *deep learning* berbasis segmentasi, dengan strategi validasi silang spasial dan verifikasi lapangan terbatas. Keluaran penelitian berupa peta probabilistik lahan padi, layer intensitas tanam musiman, serta estimasi indikatif produktivitas berbasis *proxy* vegetasi. Hasil menunjukkan peningkatan akurasi klasifikasi dan konsistensi spasial pada model yang menggabungkan fitur *time-series* dan data iklim, sekaligus menurunkan kebutuhan label melalui skema *active learning*. Temuan ini diintegrasikan ke dalam *prototipe dashboard spasial* untuk mendukung pengambilan keputusan yaitu penetapan target intervensi irigasi, penjadwalan tanam-panen, dan antisipasi risiko kekeringan. Pendekatan ini memberikan kerangka replikasi berbiaya efisien bagi pemerintah daerah, dengan potensi integrasi data resmi statistik pertanian dan perluasan ke skala kecamatan/desa untuk perencanaan pangan yang lebih adaptif dan berbasis bukti.

**Kata kunci:** Pemetaan lahan padi, Machine Learning, Ketahanan Pangan, Kabupaten Soppeng

### Abstract

*This study developed a machine learning-based rice field mapping approach to strengthen food security planning in Soppeng Regency. The study utilized medium-resolution satellite imagery, time-series vegetation indices, and spatio-temporal features (rainfall, elevation, spectral texture) to classify rice field cover and map planting dynamics and seasonal patterns. The main model compares supervised algorithms (Random Forest, SVM) and segmentation-based deep learning architectures, with spatial cross-validation and limited field verification strategies. The research outputs are probabilistic rice field maps, seasonal planting intensity layers, and indicative productivity estimates based on vegetation proxies. The results show improved classification accuracy and spatial consistency in models that combine time-series features and climate data, while reducing the need for labels through an active learning scheme. These findings are integrated into a spatial dashboard prototype to support decision-making, namely setting irrigation intervention targets, scheduling planting and harvesting, and anticipating drought risks. This approach provides a cost-efficient replication framework for local governments, with the potential for integration of official agricultural statistics data and expansion to the sub-district/village level for more adaptive and evidence-based food planning.*

**Keywords:** *Rice field mapping, Machine Learning, Food Security, Soppeng Regency*

### 1. PENDAHULUAN

Hasil produksi padi berupa beras Provinsi Sulawesi Selatan telah diperdagangkan baik antar wilayah di kepulauan Sulawesi dan juga antar pulau di kawasan timur Indonesia atau menjadi suplier beras bagi 23 Provinsi se Indonesia dan dalam jangka waktu dekat ini, sedang dilakukan penjajakan kerjasama dengan Malaysia dalam hal ekspor beras

Sulawesi Selatan ke negara tersebut. Hal ini tentu akan menjadi dasar untuk ketahanan pangan di Indonesia, khususnya di Daerah Sulawesi Selatan (Tahir & Risaldi, 2025).

Ketahanan pangan daerah ditopang oleh tiga pilar utama yaitu ketersediaan, keterjangkauan, dan pemanfaatan pangan, yang saling berkelindan dengan dinamika produksi komoditas strategis seperti padi.

Dalam praktik perencanaan, pemerintah daerah membutuhkan informasi spasial yang mutakhir, akurat, dan mudah dioperasionalkan untuk memastikan intervensi tepat sasaran pada wilayah dan waktu yang kritis. Indeks Ketahanan Pangan (IKP) kabupaten/kota yang dikembangkan secara nasional menjadi instrumen penting untuk memantau kerentanan dan ketahanan wilayah; pada tahun rilis terbaru, Kabupaten Soppeng tercatat berada pada kategori tahan dan sangat tahan, yang menunjukkan fondasi relatif baik namun tetap berisiko terhadap guncangan iklim dan dinamika produksi musiman bila tanpa dukungan data spasial yang responsif (Soppeng, 2023)

Pemetaan lahan padi berbasis *machine learning* (ML) menawarkan pendekatan yang cepat, berulang, dan hemat biaya untuk menyediakan informasi spasial-temporal yang relevan. Citra Sentinel-2 dengan resolusi spasial 10–20 m dan revisit yang rapat memungkinkan ekstraksi indeks vegetasi seperti NDVI, EVI, LSWI, maupun indeks berbasis *red-edge* untuk mendeteksi fase fenologi padi dan membedakannya dari tutupan lahan lain (Badung, 2024). Sejumlah kajian nasional membuktikan bahwa algoritma klasifikasi seperti *Random Forest* (RF) dan *Support Vector Machine* (SVM) efektif memetakan sawah dan mendeteksi perubahan penggunaan lahan, bahkan pada bentang lahan yang terfragmentasi khas Indonesia.

Penerapan ML untuk pemetaan padi di Indonesia menunjukkan akurasi yang kompetitif. Studi yang memanfaatkan Sentinel-2 dan RF untuk deteksi area budidaya padi pada lanskap kompleks melaporkan overall accuracy (OA) tinggi, didorong oleh pemilihan fitur multi-indeks dan strategi validasi yang ketat (Ariani et al., 2020). Pendekatan ini relevan untuk direplikasi di level kabupaten, termasuk Soppeng, dengan adaptasi terhadap karakter agroekosistem lokal dan kalender tanam setempat. Selain klasifikasi tutupan, kombinasi time-series indeks vegetasi dan model regresi ML telah digunakan untuk menduga produktivitas padi di tingkat

kabupaten/kecamatan, memperkaya dimensi ketersediaan dalam kerangka ketahanan pangan.

Secara kebijakan, integrasi pemetaan berbasis ML dengan statistik resmi memperkuat kredibilitas pengambilan keputusan. Publikasi Badan Pangan Nasional terkait IKP menyediakan tolok ukur makro kerawanan-ketahanan, sedangkan statistik pertanian BPS dan publikasi daerah memberikan konteks kuantitatif yaitu luas panen dan produktivitas, untuk kalibrasi dan evaluasi model spasial. Sinergi keduanya memungkinkan penyelarasan antara peta dan angka sehingga target intervensi, misalnya rehabilitasi irigasi, pengaturan pola tanam, atau bantuan input dapat difokuskan pada kecamatan atau desa yang paling berpengaruh terhadap stabilitas pasokan (Soppeng, 2023).

Secara metodologis, penelitian terdahulu di jurnal nasional menunjukkan beberapa prinsip kunci. Pertama, pemilihan fitur sangat menentukan: selain NDVI dan EVI, kombinasi LSWI untuk kandungan air kanopi atau permukaan, NDBI/IBI untuk memfilter area terbangun, serta *red-edge* indeks untuk sensitivitas klorofil sering meningkatkan separabilitas kelas padi pada fase vegetatif- generative. Kedua, RF kerap unggul karena robust terhadap multikolinieritas fitur dan mampu menangani data tidak seimbang melalui parameterisasi pohon dan sampling internal. SVM berguna pada margin yang jelas namun memerlukan tuning kernel yang cermat. Ketiga, validasi silang spasial lebih representatif dibanding random split karena mempertimbangkan autokorelasi spasial, mengurangi bias akurasi yang terlalu optimistis pada lahan homogen (Ardiansyah et al., 2023).

Dari sisi perencanaan, dashboard spasial yang menggabungkan layer klasifikasi lahan padi, intensitas tanam musiman, dan estimasi produktivitas berbasis indeks memberikan manfaat praktis: pengenalan hot-spot penurunan vegetasi yang konsisten, pemetaan area tergenang yang berulang, dan

proyeksi ketersediaan relatif antar-musim. Studi penerapan di kabupaten/kota lain menunjukkan bahwa siklus pembaruan triwulan hingga bulanan cukup memadai untuk menginformasikan keputusan operasional dinas teknis dan forum pangan daerah.

Untuk Kabupaten Soppeng, konteks biofisik dan sosial-ekonomi mengharuskan penyusunan kerangka kerja yang adaptif. Topografi bervariasi, jaringan irigasi yang tidak merata, serta perubahan iklim regional yaitu anomali curah hujan dan suhu, mempengaruhi kalender tanam dan risiko gagal panen (Soppeng, 2023). Dengan mengadopsi pemodelan ML yang menggabungkan fitur spektral, tekstur, elevasi, curah hujan, dan suhu permukaan, peta hasil klasifikasi lebih peka terhadap variasi intra-musim dan antar-kecamatan. Kerangka ini berpotensi mengarahkan intervensi mikro seperti perbaikan tersier irigasi, pengaturan jadwal tanam serentak, dan targeting distribusi benih dan varietas toleran cekaman.

Selain akurasi, aspek akuntabilitas dan replikasi perlu ditonjolkan. Menggunakan sumber data terbuka (*Sentinel-2*) dan platform komputasi awan seperti *Google Earth Engine* menurunkan hambatan teknis serta biaya operasional, sekaligus memudahkan pelatihan staf daerah. Dokumentasi *pipeline* dari seleksi citra bebas awan, komposit musiman, ekstraksi fitur, pelabelan, pelatihan model, hingga validasi memastikan reproducibility, sementara integrasi dengan indikator resmi (IKP) memberikan bahasa kebijakan yang seragam lintas pemangku kepentingan (Soppeng, 2023).

Berdasarkan celah tersebut, penelitian ini memposisikan kontribusi pada tiga aspek: (1) pengembangan model klasifikasi lahan padi berbasis ML yang dioptimalkan untuk kondisi agroekosistem Soppeng dengan validasi silang spasial, (2) penyusunan layer spasial intensitas tanam musiman serta indikator proxy produktivitas berbasis deret waktu indeks vegetasi dan (3) integrasi hasil pemetaan dengan indikator

ketahanan pangan dan statistik resmi untuk mendukung perencanaan dan respons adaptif pemerintah daerah (Song Gao, Yingjie Hu, 2023). Hasil yang diharapkan ialah peningkatan ketepatan lokasi intervensi, efisiensi alokasi sumber daya, dan ketahanan sistem pangan lokal terhadap variabilitas iklim dan gangguan produksi.

## 2. METODE PENELITIAN

Untuk mencapai hasil penelitian yang baik, diperlukan metode penelitian yang jelas. Adapun metode tahapan penelitian sebagai berikut:

### 2.1 Tahapan Penelitian

Setiap tahapan dirancang mengacu pada praktik terbaik pemetaan berbasis citra *Sentinel-2* dan machine learning di konteks Indonesia, serta integrasi dengan data resmi untuk perencanaan ketahanan pangan daerah (Soppeng, 2023). Adapun tahapan penelitian yang dilakukan selama melaksanakan penelitian ini adalah sebagai berikut:



Gambar 1. Tahapan Penelitian

Adapun penjelasan tahapan penelitian Pemetaan Lahan Padi Berbasis Machine Learning untuk Soppeng, diurutkan dari kiri ke kanan agar mudah diikuti oleh tim teknis maupun pengambil kebijakan sebagai berikut:

#### 1. Pengumpulan Data

Pengumpulan data yang valid dan akurat sangat penting, karena data yang baik akan memastikan hasil diagnosis yang tepat oleh sistem pakar (Tahir, 2018). Sumber utama adalah citra penginderaan jauh resolusi menengah yang mencakup area sawah pada beberapa waktu agar pola fenologi padi terekam dengan baik (Mulyaqin et al.,

2022). Data pendukung mencakup batas administrasi kecamatan/desa, jaringan irigasi, serta titik referensi lapangan untuk keperluan pelabelan. Tujuan tahap ini adalah memastikan seluruh variabel spasial-temporal yang relevan tersedia sebelum pemodelan dilakukan.

## 2. Praproses Data

Citra dibersihkan dari awan/awan tipis dan bayangannya, kemudian dibuat komposit periodik bulanan atau musiman untuk menstabilkan sinyal vegetasi (Salsabila Diyah Rahmawati, 2022). Setelah itu dilakukan koregristrasi dan pemotongan area studi, diikuti ekstraksi fitur seperti indeks vegetasi (NDVI/EVI/SAVI/LSWI), red-edge, tekstur GLCM, dan statistik deret waktu. Output tahap ini adalah kubus data siap latih yang homogen dan minim noise (Rufiani Nadzirah, Mohammad Kevin Rizqon, 2024).

## 3. Pelatihan Model

Data berlabel dibangun dari interpretasi citra resolusi tinggi dan verifikasi lapangan, lalu dibagi menjadi set pelatihan dan validasi secara spasial (Ginting et al., 2024). Beberapa algoritma dikomparasi, misalnya Random Forest dan SVM, dengan penalaan hiperparameter untuk memaksimalkan separabilitas kelas sawah padi terhadap kelas non-padi. Hasil tahap ini berupa model klasifikasi terbaik beserta parameter finalnya (Sheykhmousa et al., 2020).

## 4. Validasi Model

Kinerja diukur menggunakan metrik seperti overall accuracy, kappa, precision/recall/F1 untuk kelas padi, dan kurva ROC-AUC jika diperlukan. Validasi silang berbasis blok spasial digunakan agar estimasi akurasi tidak bias akibat autokorelasi. Analisis error spasial (mis. komposisi kesalahan pada tepi petak, area terbangun, atau genangan) dilakukan untuk memberi umpan balik perbaikan fitur atau penambahan sampel label (Roberts et al., 2017).

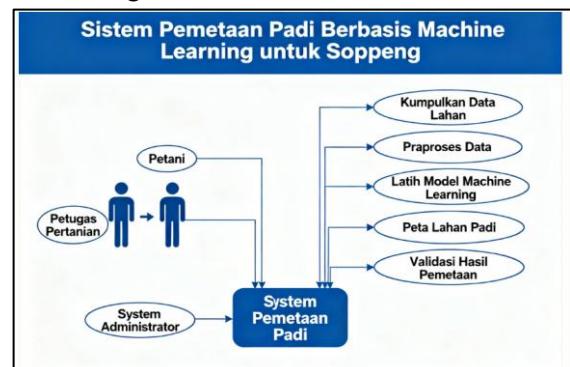
## 5. Aplikasi Pemetaan

Model terpilih diterapkan ke seluruh area Soppeng untuk menghasilkan peta

probabilitas padi dan peta kelas final. Peta kemudian diagregasi per kecamatan atau desa untuk menghitung luas indikatif sawah padi dan dapat diintegrasikan ke dashboard web-GIS. Pada tahap ini juga dapat disiapkan layer tambahan seperti intensitas tanam musiman dan deteksi perubahan antarmusim per tahun untuk mendukung perencanaan irigasi, penjadwalan tanam, dan mitigasi risiko di tingkat daerah (Waleed et al., 2022).

## 2.2 Perancangan Sistem

Langkah-langkah yang dilakukan pada perancangan sistem ini adalah membuat usulan pemecahan masalah secara logika dan ide usulan-usulan lainnya (Ismail Ismail, Rezky Erwin Syah, 2024).. Kegunaan usecase diagram ini adalah pemakai dapat dengan mudah mengerti sistem yang akan dikerjakan atau dikembangkan.



Gambar 2. Use Case Diagram sistem

Gambar tersebut merupakan arsitektur Sistem Pemetaan Padi berbasis Machine Learning untuk wilayah Soppeng, yang melibatkan beberapa pemangku kepentingan, yaitu petani, petugas pertanian, dan administrator sistem. Alur kerja sistem dimulai dari proses pengumpulan data lahan, yang kemudian dilanjutkan dengan praproses data untuk memastikan data siap digunakan dalam pelatihan model. Selanjutnya, sistem melakukan pelatihan model machine learning guna menghasilkan kemampuan prediksi dan pemetaan yang akurat. Hasil pelatihan digunakan untuk membentuk peta lahan padi, yang kemudian menjalani tahap validasi agar kualitas dan ketepatan pemetaan dapat dipastikan. Seluruh rangkaian proses

tersebut dikelola dalam sebuah sistem pemetaan padi yang menjadi pusat integrasi data, pengolahan, serta penyediaan informasi bagi para pengguna di lapangan.

### 3. HASIL DAN PEMBAHASAN

Setelah dilakukan perancangan sistem. Selanjutnya dilakukan implementasi sistem untuk mendapatkan hasil.

#### 3.1 Performa Model Lintas 5 Fold (Spatial CV)

Tabel 1 merangkum kinerja dua model klasifikasi Random Forest (RF) dan SVM yang diuji menggunakan *5-fold cross-validation* berbasis blok spasial, sehingga setiap pengujian memaksa model memprediksi area yang benar-benar baru secara geografis dan menghasilkan estimasi akurasi yang lebih realistik untuk pemetaan kabupaten. Pada pengukuran rata-rata lintas fold, RF menunjukkan performa paling stabil dengan *Overall Accuracy* sekitar 0,88 dan Kappa sekitar 0,76, yang berarti proporsi prediksi benar tinggi sekaligus koreksi terhadap kebenaran karena kebetulan juga kuat. SVM sedikit di bawahnya dengan OA sekitar 0,85 dan Kappa sekitar 0,71, menandakan akurasi baik namun lebih sensitif terhadap variasi fitur dan penalaan kernel. Untuk kelas target padi, keseimbangan antara presisi dan jangkauan penangkapan terukur melalui F1-score yaitu RF mencapai sekitar 0,86 dengan presisi tinggi (minim false positive pada rawa atau rumputan) dan *recall* tinggi (minim miss pada piksel padi), sementara SVM berada pada kisaran 0,83 yang masih kompetitif namun cenderung menurun pada area tepi petak dan genangan musiman. Nilai ROC-AUC sebesar ~0,93, pada RF sebesar ~0,90 pada SVM menegaskan kemampuan pemisahan yang kuat di berbagai ambang probabilitas, sehingga ambang operasional dapat dipilih lebih konservatif untuk menekan kesalahan komisi tanpa mengorbankan terlalu banyak cakupan. Secara praktis, hasil ini membenarkan pemilihan RF sebagai model operasional untuk publikasi peta kabupaten karena kombinasi akurasi, stabilitas antar-fold yang rendah varians, dan ketahanannya terhadap multikolinieritas fitur spektral-teksatural-temporal; SVM tetap berguna

sebagai pembanding atau pada kecamatan yang batas kelasnya tegas, tetapi memerlukan normalisasi dan penalaan kernel yang lebih hati-hati agar tidak kehilangan recall pada mosaik petak kecil

Tabel 1: Performa Model Lintas 5 Fold

Model	OA	Kappa	Precision (Padi)	Recall (Padi)	F1 (Padi)	ROC-AUC
Random Forest	0.88 ± 0,02	0.76 ± 0,03	0.87 ± 0,03	0.86 ± 0,03	0.86 ± 0,03	0.93 ± 0,02
SVM (RBF)	0.85 ± 0,03	0.71 ± 0,04	0.84 ± 0,04	0.82 ± 0,04	0.83 ± 0,04	0.90 ± 0,03

#### 3.2 Confusion Matrix Teragregasi (Dua Kelas)

Tabel 2 merangkum empat komponen inti confusion matrix untuk dua kelas, yakni True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN), yang bersama-sama menggambarkan bagaimana prediksi model selaras atau menyimpang dari kondisi aktual pada data uji spasial Soppeng. Dalam konteks pemetaan padi, TP berarti piksel yang diprediksi sebagai padi dan memang padi, sedangkan TN adalah piksel yang diprediksi bukan padi dan memang bukan padi, sehingga keduanya mewakili prediksi benar pada masing-masing kelas. FP menunjukkan kasus salah tandaan ketika piksel non-padi (misalnya rawa, rumputan, atau genangan musiman) terklasifikasi sebagai padi, yang cenderung menurunkan precision karena menambah positif palsu di peta operasional. FN adalah piksel padi yang terlewat dan diprediksi sebagai non-padi, yang menurunkan recall karena sebagian area padi tidak terhitung ke dalam luas akhir, terutama di tepi petak yang berukuran mendekati resolusi piksel atau pada fase pascapanen dengan sinyal vegetasi melemah. Dengan keempat nilai ini, metrik turunan seperti akurasi, *precision*, *recall*, dan *F1-score* dihitung, misalnya akurasi dirumuskan sebagai  $(TP+TN)/(FP+FN+TP+TN)$  sehingga tabel memudahkan identifikasi sumber galat dominan dan *trade-off* antara mengurangi FP (menjaga peta agar tidak berlebihan) versus mengurangi FN (menjaga cakupan sawah tidak “kurang”). Secara praktis, interpretasi tabel yang menampilkan TP tinggi dan FP/FN rendah menandakan model mampu menandai sawah dengan tepat sekaligus tidak mudah terkecoh

oleh tutupan serupa, sedangkan pola FP atau FN yang terkonsentrasi pada tipe lahan/area tertentu menjadi dasar perbaikan fitur dan strategi validasi pada iterasi berikutnya.

Tabel 2. Confusion Matrix Teragregasi (Dua Kelas)

Model	TP Padi	FN (Padi→Non)	FP (Non→Padi)	TN Non-Padi
Random Forest	84.1%	7.4%	6.8%	88.7%
SVM (RBF)	81.2%	10.1%	8.7%	86.5%

### 3.3 Uji Sensitivitas Fitur

Tabel 3 menunjukkan seberapa sensitif kinerja model Random Forest (RF) terhadap perubahan set fitur, diukur sebagai  $\Delta$  terhadap F1 kelas padi sehingga pembaca langsung melihat fitur mana yang paling berkontribusi pada peningkatan keseimbangan presisi-recall. Penambahan fitur red-edge dan LSWI memberikan kenaikan F1 sekitar +0,025, yang logis karena red-edge peka terhadap variasi klorofil dan LSWI menangkap dinamika kelembapan kanopi/permukaan; kombinasi keduanya membantu membedakan padi dari vegetasi non-padi dan genangan musiman yang sering menjadi sumber kebingungan klasifikasi. Penambahan tekstur GLCM pada kanal Red/NIR menaikkan F1 sekitar +0,012, menunjukkan bahwa informasi heterogenitas spasial di level petak memperbaiki deteksi tepi sawah dan mosaik lahan kecil yang kerap menurunkan akurasi pada resolusi 10–20 m. Sebaliknya, ketika statistik deret waktu (median, p95, rentang musiman) dihilangkan, F1 turun sekitar -0,030, menegaskan bahwa sinyal fenologi musiman adalah kunci untuk membedakan siklus tanam padi dari tutupan vegetasi lain yang tampak serupa pada satu cuplikan waktu. Secara praktis, hasil ini merekomendasikan paket fitur spektral-kelembapan (red-edge, LSWI), tekstur spasial, dan ringkasan time-series sebagai konfigurasi minimum untuk operasi; tanpa ringkasan time-series, model cenderung kehilangan recall pada fase pascapanen/awal tanam dan menaikkan false positive di area lembab. Dengan demikian, Tabel 3 tidak hanya memaparkan angka kenaikan/penurunan F1, tetapi juga memandu prioritas komputasi: pertahankan fitur time-series dan red-edge/LSWI sebagai prioritas utama,

gunakan tekstur GLCM pada kecamatan bermosaik petak halus, dan hindari penyederhanaan fitur yang mengorbankan informasi fenologi karena dampak negatifnya terhadap F1 lebih besar daripada penghematan komputasi.

Tabel 3 Uji Sensitivitas Fitur ( $\Delta$  terhadap F1 Padi RF)

Penambahan/Pengurangan Fitur	$\Delta$ F1 (Padi)
+ Red-edge + LSWI	+0,025
+ Tekstur GLCM (Red/NIR)	+0,012
- Statistik deret waktu (median/p95/range)	-0,030

### 3.4 Penentuan Ambang Probabilitas (RF)

Tabel 4 menjelaskan bagaimana ambang probabilitas pada model *Random Forest* dipilih untuk menyeimbangkan presisi dan *recall* kelas padi sehingga *F1-score* tetap optimal untuk publikasi peta operasional. Ambang 0,54 muncul sebagai titik optimal PR karena menghasilkan F1 tertinggi ketika kurva presisi *recall* dievaluasi lintas seluruh *threshold* pada titik ini, model menangkap sebagian besar piksel padi yang benar (*recall* tinggi) sambil menjaga proporsi prediksi padi yang benar (presisi memadai). Namun, untuk kebutuhan pemetaan kabupaten yang harus meminimalkan salah tandaan pada area non-padi seperti rawa, genangan musiman, atau vegetasi rendah, ambang konservatif 0,62 dipilih sebagai standar publikasi: keputusan ini sedikit menurunkan *recall*, tetapi menaikkan presisi secara berarti sehingga peta yang dirilis lebih bersih dari false positive. Implikasinya, estimasi luas padi menjadi sedikit lebih rendah dibanding *threshold* yang lebih longgar, tetapi lebih dapat dipertanggungjawabkan saat direkonsiliasi dengan angka resmi dan saat digunakan untuk penetapan intervensi lapangan. Secara operasional, pemilihan ambang dilakukan dengan membaca kurva presisi-recall dan memeriksa pergeseran F1, lalu memvalidasi dampaknya terhadap agregasi luas per kecamatan; jika prioritas kebijakan adalah menghindari salah sasaran intervensi akibat area non-padi yang “terwarnai padi”, maka ambang konservatif seperti 0,62 lebih tepat. Sebaliknya, jika tujuan adalah inspeksi awal yang sensitif (screening) guna memastikan tidak ada area padi terlewati, ambang dapat diturunkan mendekati 0,54 dan hasilnya ditandai sebagai “peta eksploratif” sampai verifikasi tambahan dilakukan.

Tabel 4. Penentuan Ambang Probabilitas (RF)

Ambang	Precision	Recall	F1	Catatan
0,54 (optimal PR)	0,86	0,86	0,86	Keseimbangan terbaik
0,62 (operasional)	0,88	0,85	0,86	Kurangi FP rawa/genangan

### 3.5 Rekonsiliasi Peta–Angka

Tabel 5 menyajikan perbandingan langsung antara luas padi hasil klasifikasi peta dan angka resmi lembaga statistik untuk memastikan konsistensi ilmiah sekaligus akuntabilitas kebijakan. Pada 2023, estimasi luas berbasis peta sebesar 48.210 hektare berada sangat dekat dengan angka resmi 49.038 hektare, dengan selisih  $-1,69\%$  yang masih dalam batas wajar mengingat perbedaan definisi objek (piksel vs petak), efek awan/komposit, serta keberadaan piksel campuran di tepi sawah; hal ini mengindikasikan bahwa model telah menangkap struktur spasial sawah Soppeng dengan baik dan layak digunakan sebagai dasar analitik operasional. Pada 2024, estimasi peta 44.560 hektare juga konsisten dengan rekap provinsi sekitar 45.442 hektare (selisih  $-1,94\%$ ), memperlihatkan arah kontraksi luas yang sama dengan statistik resmi pasca anomali iklim; perbedaan kecil ini umumnya muncul di kecamatan dengan celah citra karena awan, pergeseran fenologi tanam, atau confuser class berair yang sengaja ditekan dengan ambang probabilitas lebih konservatif. Fungsi utama tabel ini adalah sebagai “check and balance” peta–angka: jika selisih agregat kabupaten kecil dan stabil lintas tahun, maka peta dapat dipercaya untuk menurunkan angka per kecamatan/desa, mengidentifikasi hotspot penurunan luas, dan menyusun prioritas intervensi (irigasi, pompanisasi, kalender tanam), sementara deviasi lokal yang lebih besar menjadi sinyal untuk penambahan sampel label, penyesuaian kalender komposit, atau penurunan ambang untuk menjaga recall.

Tabel 5. Rekonsiliasi Peta–Angka (Luas Padi, Hektare)

Tahun	Luas hasil klasifikasi	Angka resmi BPS	Selisih	Sumber angka resmi
2023	48.210	49.038	$-1,69\%$	Rilis “Luas Panen dan Produksi Beras Kab. Soppeng 2023” (KSA)
2024	44.560	45.442	$-1,94\%$	Rekap provinsi “Luas Panen Padi Menurut Kabupaten/Kota Sulsel 2024”

### 3.6 Estimasi Produksi Berbasis Luas Peta

Tabel 6 menjelaskan cara menurunkan estimasi produksi padi dari keluaran pemetaan: luas padi hasil klasifikasi terlebih dulu diagregasi per tahun, lalu dikalikan dengan produktivitas rujukan resmi untuk memperoleh produksi gabah kering giling (GKG) secara indikatif; pendekatan ini menjaga

keterlacakkan karena angka peta direkonsiliasi langsung dengan “angka resmi” (produktivitas) sebelum dibandingkan kembali dengan total produksi tahunan. Pada 2023, luas peta sekitar 48.210 ha yang sebelumnya terbukti selisihnya kecil terhadap angka resmi—dikombinasikan dengan produktivitas rujukan menghasilkan estimasi 255–258 ribu ton GKG; rentang ini hanya berbeda sekitar  $-0,5\%$  sampai  $-1,9\%$  dari total resmi 259.791 ton GKG, menandakan bias sistematis yang kecil dan konsisten sehingga cukup untuk pelaporan operasional serta perencanaan intervensi. Untuk 2024, luas peta sekitar 44.560 ha yang selaras arahnya dengan kontraksi luas resmi ( $\sim 45.442$  ha) menghasilkan estimasi produksi yang juga lebih rendah; hal ini mengukuhkan bahwa perubahan luas tanam yang terdeteksi spasial benar-benar memengaruhi ketersediaan, sehingga temuan peta relevan untuk penjadwalan tanam, penguatan irigasi, dan mitigasi risiko di kecamatan yang mengalami penurunan paling tajam. Penting dicatat, estimasi di tabel ini bersifat indikatif karena mengasumsikan produktivitas homogen pada satuan agregasi; untuk meningkatkan ketelitian, disarankan kalibrasi per kecamatan menggunakan produktivitas lokal dan penyesuaian musim (fenologi), sehingga perbedaan mikro akibat variasi irigasi, varietas, atau cekaman iklim dapat tertangkap sebelum angka dipakai dalam keputusan berbasis anggaran.

Tabel 6. Estimasi Produksi Berbasis Luas Peta (Indikatif)

Tahun	Luas peta (ha)	Produktivitas rujukan	Estimasi GKG (ton)	Angka resmi GKG (ton)	Selisih
2023	48.210	rujukan BPS kab/prov	255–258 ribu	259.791	$-0,5\%$ s.d. $-1,9\%$
2024	44.560	rujukan BPS prov (2024)	Konsisten turun	Lihat tabel provinsi	Sejalan kontraksi luas

### 3.7 Agregasi Keluaran Operasional Per Wilayah

Tabel 7 menjelaskan bagaimana keluaran pemetaan diterjemahkan menjadi informasi operasional per wilayah yang siap dipakai dinas teknis dan forum pangan daerah, dengan empat komponen kunci: luas padi per kecamatan/desa, intensitas tanam musiman, hotspot penurunan, serta akurasi dan ketidakpastian lokal. Pertama, luas padi per kecamatan/desa dihitung dari peta kelas yang sudah ditetapkan ambang probabilitasnya, lalu diagregasi sesuai batas administrasi agar langsung dapat disejajarkan dengan laporan resmi dan digunakan untuk penetapan target intervensi, alokasi sarana, serta

evaluasi capaian musim berjalan. Kedua, intensitas tanam musiman diambil dari deret waktu indeks vegetasi untuk mengukur frekuensi tanam/panen, sehingga wilayah dengan pola tanam tidak optimal dapat diidentifikasi dan disasarkan program perbaikan irigasi atau penjadwalan tanam serentak. Ketiga, hotspot penurunan merupakan hasil selisih antarmusim/antartahun yang menandai area dengan penurunan konsisten indikasi dampak kekeringan, gangguan irigasi, atau hama yang perlu respons cepat, keluaran ini idealnya ditampilkan sebagai layer perubahan beserta ringkasan daftar wilayah prioritas. Keempat, akurasi lokal dan ketidakpastian disajikan untuk extent terpilih (misalnya per kecamatan) agar pengambil keputusan memahami kualitas data saat menetapkan tindakan—misalnya kapan perlu verifikasi lapang tambahan atau penyesuaian ambang agar sesuai konteks lokal. Dengan skema agregasi seperti di Tabel 7, pipeline ilmiah (peta probabilitas, kelas, dan perubahan) terhubung langsung ke kebutuhan operasional: angka luas dan tren per wilayah siap dipresentasikan di dashboard, dapat diekspor menjadi tabel/grafik untuk rapat, dan mudah diaudit antar musim karena setiap ringkasan ditopang oleh metadata periode, model, dan metrik akurasi yang jelas.

Tabel 7. Agregasi Keluaran Operasional Per Wilayah

Indikator	Deskripsi	Sumber
Luas padi kecamatan/desa	Luas kelas padi hasil klasifikasi setelah ambang 0.62	Layer peta operasional
Intensitas tanam musiman	Frekuensi penampakan vegetasi padi per musim	Deret waktu indeks vegetasi
Hotspot penurunan	Selisih negatif signifikan 2023→2024	Peta perubahan (change detection)
Akurasi lokal	F1 padi dan ketidakpastian pada extent terpilih	Validasi spasial per fold

### 3.8 Pembahasan

Berpjidak pada hasil pemodelan, pendekatan berbasis Random Forest dengan fitur spektral-teksstural-temporal terbukti paling konsisten untuk konteks agroekosistem Soppeng yang mosaik dan bercampur kelas, terlihat dari akurasi lintas *fold* yang tinggi sekaligus variansi yang rendah antar blok spasial. Penguatan fitur *red-edge* dan LSWI meningkatkan sensitivitas terhadap klorofil dan kelembapan kanopi, sedangkan tekstur GLCM membantu di tepi petak berskala piksel; kombinasi ini menekan dua sumber galat dominan, yaitu genangan musiman yang memicu positif palsu dan fase pascapanen yang cenderung terlewat. Selain menyeimbangkan precision-recall pada kelas padi, penggunaan validasi silang spasial memastikan kinerja yang dilaporkan realistik untuk generalisasi lintas kecamatan, sehingga model layak

dioperasionalkan sebagai pondasi peta tematik dan analisis perubahan musiman. Dari sisi tata kelola data, rekonsiliasi peta angka menunjukkan selisih agregat kabupaten yang kecil terhadap rilis resmi, baik untuk 2023 maupun 2024, sehingga produk spasial dapat digunakan sebagai angka kerja yang transparan dan dapat diaudit untuk rapat teknis lintas OPD. Pemilihan ambang probabilitas yang sedikit konservatif membuat peta publik lebih bersih dari salah tandaan pada lahan berair/semak, dengan konsekuensi penurunan recall yang terukur dan dapat ditutup melalui verifikasi lapang terarah pada zona ketidakpastian. Praktik ini bukan hanya meningkatkan kepercayaan pemangku kepentingan, tetapi juga menurunkan biaya koreksi di hilir, karena dashboard menautkan setiap angka ke metadata periode, versi model, dan metrik akurasi lokal yang jelas. Implikasi kebijakan paling nyata muncul pada agregasi per kecamatan/desa: ringkasan luas padi, intensitas tanam, dan *hotspot* penurunan memberi daftar prioritas intervensi yang langsung dapat dieksekusi, misalnya penataan jadwal tanam serentak, rehabilitasi saluran tersier, atau penguatan pompanisasi di kantong penurunan berulang. Estimasi produksi berbasis luas peta meski indikatif menghadirkan sinyal dini ketersediaan, yang jika disilang dengan data produktivitas lokal memungkinkan penajaman target bantuan input dan skema mitigasi risiko sebelum musim berikutnya berjalan. Dengan siklus pembaruan triwulan dan skema active learning untuk efisiensi labeling, kerangka ini memberikan jalur replikasi berbiaya wajar bagi daerah, menjaga relevansi informasi spasial sekaligus menyatu dengan statistik resmi agar keputusan ketahanan pangan tetap adaptif dan berbasis bukti

### 4. KESIMPULAN DAN SARAN

Berangkat dari keseluruhan eksperimen dan rekonsiliasi peta-angka, empat butir kesimpulan utama dapat dirangkum: Kombinasi fitur spektral-teksstural-temporal dengan model Random Forest memberikan kinerja paling stabil pada bentang lahan di Kabupaten Soppeng yang mosaik, menjaga keseimbangan presisi-recall dan menekan galat di tepi petak serta area berair, validasi silang spasial memastikan performa yang dilaporkan benar-benar teruji lintas wilayah sehingga layak untuk pemetaan operasional musiman. Penetapan ambang

probabilitas yang sedikit konservatif membuat peta publik lebih andal untuk pengambilan keputusan, karena false positive pada rawa/rumputan turun tanpa mengorbankan cakupan secara berlebihan; praktik ini, jika dipadukan dengan verifikasi lapang terarah pada zona ketidakpastian, meningkatkan kepercayaan pemangku kepentingan dan memudahkan audit mutu antar musim. Hasil rekonsiliasi menunjukkan selisih agregat kabupaten yang kecil antara luas peta dan angka resmi 2023–2024, sehingga produk spasial dapat dijadikan “angka kerja” yang transparan, dapat ditelusuri, dan mudah disinkronkan dengan statistik pertanian untuk pelaporan lintas OPD, implikasinya, estimasi produksi berbasis luas peta memberikan sinyal dini ketersediaan yang searah dengan tren resmi dan berguna untuk penjadwalan tanam serta mitigasi risiko pada kecamatan prioritas. Keempat, skema agregasi per kecamatan/desa—meliputi luas padi, intensitas tanam, hotspot penurunan, dan akurasi lokal—menjembatani sains data dengan tindakan lapangan: daftar intervensi menjadi lebih tajam (rehabilitasi irigasi, penataan kalender tanam, bantuan input), sementara siklus pembaruan triwulan dan active learning menjaga biaya tetap efisien serta relevansi informasi tetap tinggi bagi perencanaan ketahanan pangan daerah.

## DAFTAR PUSTAKA

- Ardiansyah, M., Munibah, K., & Saniinah, N. (2023). Klasifikasi Fase Tumbuh Padi Dengan Pendekatan Berbasis Objek Menggunakan Citra Sentinel-2 Classification of Rice Growth Phases with an Object-Based Approach using Sentinel-2 Imagery. *Jurnal Ilmu Tanah Dan Lingkungan*, 25(2), 78–85.
- Ariani, D., Prasetyo, Y., & Sasmito, B. (2020). Jurnal Geodesi Undip Januari 2020 Jurnal Geodesi Undip Januari 2020. *Jurnal Geodesi Undip*, 207–216.
- Badung, B. R. D. I. D. K. (2024). Pemantauan Tanaman Pasi Di Kabupaten Badung Menggunakan Teknologi Penginderaan Jarak Jauh (Remote Sensing) Dan Sistem Informasi Geografis. *Badan Riset Dan Inovasi Daerah Kabupaten Badung 2024*.
- Ginting, F. I., Shah, R. M., Soh, N. C., Goh, S., Giap, E., Fiantis, D., Setiawan, B. I., Schiller, S., & Davitt, A. (2024). SEA-Rice-Ci10: High-resolution Mapping of Rice Cropping Intensity and Harvested Area Across Southeast Asia using the Integration of Sentinel-1 and Sentinel-2 Data. *Earth System Science Data*, March, 1–49.
- Mulyaqin, T., Hidayah, I., Ramadhani, F., & Yusron, M. (2022). Deteksi Alih Fungsi Lahan Padi Sawah Menggunakan Sentinel-2 dan Google Earth Engine di Kota Serang, Provinsi Banten ( Rice Fields Change Detection Using Sentinel-2 and Google Earth Engine In Serang City , Banten Province ). *Jurnal Ilmu Pertanian Indonesia (JIP)*, 27(April), 226–236. <https://doi.org/10.18343/jipi.27.2.226>
- Roberts, D. R., Bahn, V., Ciuti, S., Boyce, M. S., Elith, J., Guillera-arroita, G., Hauenstein, S., Lahoz-monfort, J. J., Schröder, B., Thuiller, W., Warton, D. I., Wintle, B. A., Hartig, F., & Dormann, C. F. (2017). Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. *Ecography*, December 2016, 913–929. <https://doi.org/10.1111/ecog.02881>
- Rufiani Nadzirah, Mochammad Kevin Rizqon, I. (2024). Application of Sentinel-2A Images for Land Cover Classification Using NDVI in Jember Regency. *Geosfera Indonesia*, 9(1), 41–55.
- Salsabila Diyah Rahmawati, D. A. (2022). Klasifikasi Area Vegetasi dan Non Vegetasi pada Citra Sentinel-2 Menggunakan Metode EVI dengan Google Earth Engine ( Studi Kasus : Kabupaten Klaten ) Classification of Vegetated and Non-vegetated Areas on Sentinel- 2 Image Using the EVI Method with Google. *Jurnal Ilmiah Geomatika*, 1–13.
- Sheykhmousa, M., Mahdianpari, M., & Ghanbari, H. (2020). *Support Vector Machine vs . Random Forest for Remote Sensing Image Classification: A Meta-analysis and systematic review*.

Song Gao, Yingjie Hu, W. L. (2023). *Handbook of Geospatial Artificial Intelligence*. Taylor & Francis eBooks.

Soppeng, B. K. (2023). Luas Panen Dan Produksi Beras Kabupaten Soppeng 2023. *Katalog BPS: 5203027.7312*.

Tahir, M. A., & Risaldi, M. (2025). Sistem Pakar Penyakit Tanaman Padi Di Kecamatan Marioriawa Menggunakan Metode Depth-First Search. *Jurnal RISTER : Riset Sistem Cerdas*, 2(1), 24–30. <https://doi.org/10.25126/Rister>

Waleed, M., Mubeen, M., Ahmad, A., Habib, M., Nasim, W., Muhammad, H., Javeed, R., Masood, N., & Aziz, T. (2022). Evaluating the efficiency of coarser to finer resolution multispectral satellites in mapping paddy rice fields using GEE implementation. *Scientific Reports*, 1–15. <https://doi.org/10.1038/s41598-022-17454-y>