

Analisis Produktivitas Padi Menggunakan UAV Multispektral Dan Support Vector Regression Dengan Optimasi Grid Search Di Balumbang Jaya, Bogor Barat

Nur Annisa Indah Lestari^{1*}, Erwin Hermawan¹, Sahid Agustian Hudjimartsu¹, Arif K Wijayanto², Ahmad Junaedi³, Dan Miftahul B.R. Khamid⁴

¹Program Studi Teknik Informatika, Fakultas Teknik dan Sains, Universitas Ibn Khaldun Bogor, Jawa Barat, Indonesia

²Departemen Konservasi Sumberdaya Hutan dan Ekowisata, Fakultas Kehutanan dan Lingkungan, Institut Pertanian Bogor, Jawa Barat, Indonesia

³Departemen Agronomi dan Hultikultura, Fakultas Pertanian, Institut Pertanian Bogor, Jawa Barat, Indonesia

⁴Program Studi Agroteknologi, Fakultas Pertanian, Universitas Singaperbangsa Karawang, Jawa Barat, Indonesia

***E-mail:** nurannisa.ilestari@gmail.com

Received: 29 11 2024 / Accepted: 30 06 2025 / Published online: 24 07 2025

ABSTRAK

Produktivitas padi merupakan indikator penting dalam ketahanan pangan nasional, sehingga diperlukan pendekatan analitis yang akurat untuk memantau dan memprediksi hasil panen secara spasial. Penelitian ini bertujuan mengembangkan model prediksi produktivitas padi menggunakan teknologi penginderaan jarak jauh dengan *Unmanned Aerial Vehicle (UAV)* dan metode *Support Vector Regression (SVR)*. Studi dilaksanakan di Kelurahan Balumbang Jaya, Kabupaten Bogor Barat, dengan jumlah sampel terbatas sebanyak 30 plot sawah. Lima indeks vegetasi yang dianalisis mencakup: *Normalized Difference Vegetation Index (NDVI)*, *Green Normalized Difference Vegetation Index (GNDVI)*, *Normalized Difference Red Edge (NDRE)*, *Optimized Soil-Adjusted Vegetation Index (OSAVI)*, dan *Leaf Chlorophyll Index (LCI)*. Metodologi penelitian mengintegrasikan teknik penginderaan jauh, pengolahan citra multispektral, dan *machine learning*. Parameter optimal SVR diperoleh melalui *grid search* dengan nilai $\sigma=1$ dan $\text{cost}=1$. Teknik *Synthetic Minority Over-sampling Technique (SMOTE)* diterapkan dalam tahap klasifikasi awal data untuk menyeimbangkan distribusi kelas produktivitas, meskipun penelitian ini berfokus pada regresi. Hasil penelitian menunjukkan model SVR dengan kernel *Radial Basis Function (RBF)* mampu menjelaskan 87,6% variabilitas produktivitas padi dengan *Root Mean Squared Error (RMSE)* 0,29 ton/ha. Temuan penelitian mengkonfirmasi efektivitas pendekatan multidisipliner dalam menghasilkan model prediksi produktivitas padi yang akurat dan inovatif. Model ini berpotensi digunakan sebagai alat pendukung pengambilan keputusan dalam pengelolaan lahan pertanian yang lebih efisien dan responsif terhadap variabilitas lingkungan.

Kata Kunci: Produktivitas Padi, Indeks Vegetasi, UAV Multispektral, *Support Vector Regression*, Optimasi Grid Search.

ABSTRACT

Rice productivity is an important indicator of national food security, so an accurate analytical approach is needed to monitor and predict harvest yields spatially. This research aims to develop a rice productivity prediction model using remote sensing technology with Unmanned Aerial Vehicle (UAV) and Support Vector Regression (SVR) method. The study was conducted in Balumbang Jaya Village, West Bogor Regency, with a limited sample size of 30 rice field plots. Five vegetation indices were analyzed, including: Normalized

Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI), Normalized Difference Red Edge (NDRE), Optimized Soil-Adjusted Vegetation Index (OSAVI), and Leaf Chlorophyll Index (LCI). The research methodology integrated remote sensing techniques, multispectral image processing, and machine learning. The optimal SVR parameters were obtained through grid search with $\sigma=1$ and $\text{cost}=1$. The Synthetic Minority Over-sampling Technique (SMOTE) was applied in initial data classification stage to balance the productivity class distribution, although this study focused on regression. The results show that the SVR model with Radial Basis Function (RBF) kernel can explain 87.6% of rice productivity variability with a Root Mean Squared Error (RMSE) of 0.29 ton/ha. The findings confirm the effectiveness of a multidisciplinary approach in developing accurate and innovative rice productivity prediction models. This model has the potential to be used as a decision-making tool in agricultural land management that is more efficient and responsive to environmental variability.

Keywords: *Rice Productivity, Vegetation Index, Multispectral UAV, Support Vector Regression, Grid Search Optimization*

PENDAHULUAN

Pangan merupakan kebutuhan strategis yang menentukan ketahanan nasional, dengan beras sebagai komoditas utama di Indonesia. Sebagai negara agraris, Indonesia memiliki potensi produksi padi yang signifikan, tercermin dari luasan lahan pertanian mencapai 10,61 juta hektar pada tahun 2022. Kompleksitas pengelolaan lahan pertanian saat ini menghadapi tantangan multidimensional, meliputi konversi lahan, perubahan iklim, dan dinamika sosial ekonomi yang terus berkembang (Yanuaeva et al., 2023).

Transformasi penggunaan lahan pertanian menjadi area non-pertanian, khususnya di wilayah perkotaan, menimbulkan konsekuensi serius terhadap produktivitas pertanian. Studi empiris di Kelurahan Balumbang Jaya, Kota Bogor, menunjukkan fenomena perubahan fungsi lahan sawah menjadi kawasan permukiman dan area komersial, yang secara signifikan memengaruhi kapasitas produksi pertanian lokal (Gandhi & Darmawan, 2022; Jannah et al., 2020). Lokasi ini mengalami konversi lahan sawah sebesar 24,6% selama lima tahun terakhir (Bappeda Kota Bogor, 2023), yang berdampak langsung terhadap penurunan luas lahan produktif. Selain itu,

karakteristik wilayah yang datar dan minim halangan fisik mendukung pengambilan data menggunakan UAV secara optimal.

Kompleksitas dalam memprediksi produktivitas padi memerlukan pendekatan teknologi yang lebih presisi dan adaptif. Perkembangan teknologi *Unmanned Aerial Vehicle (UAV)* dengan sensor multispektral menawarkan solusi baru untuk pemantauan pertumbuhan tanaman melalui data resolusi tinggi (Ariani et al., 2020; Sunito, 2019). Indeks vegetasi seperti *Normalized Difference Vegetation Index (NDVI)*, *Normalized Difference Red Edge Index (NDRE)*, *Green Normalized Difference Vegetation Index (GNDVI)*, *Optimization Soil-Adjusted Vegetation Index (OSAVI)*, dan *Leaf Chlorophyll Index (LCI)* memberikan indikator kuantitatif yang kuat dalam menilai kondisi tanaman (Fajri et al., 2022).

Metode *Support Vector Regression (SVR)* merupakan salah satu algoritma machine learning yang efektif untuk menangani hubungan non-linear dalam prediksi produktivitas. Penelitian sebelumnya oleh (Wardana et al., 2019) menggunakan SVR untuk memodelkan tinggi tanaman padi, namun hanya mencapai nilai *Mean Absolute Percentage*

Error (MAPE) sebesar 35,426%. Studi oleh (S. Liu et al., 2021) di Kalimantan Selatan menunjukkan kemampuan *SVR* dalam memodelkan pengaruh perubahan iklim terhadap produktivitas padi, meskipun tanpa optimasi parameter secara eksplisit.

Beberapa studi lain juga melaporkan nilai R^2 dan akurasi yang relatif rendah. Penelitian (Z. Liu et al., 2024) di Jiangsu, Tiongkok, mencatat $R^2 \approx 0,65$ menggunakan *SVR* atau *PLSR* berbasis *NDVI* multi-temporal. Pada penelitian (Quille-Mamani et al., 2025) di Lambayeque, Peru, *SVR-RBF* hanya mencapai R^2_{CV} sekitar 0,24-0,26. Perbandingan ini menunjukkan masih adanya ruang peningkatan dalam pemanfaatan *SVR* untuk prediksi hasil pertanian.

Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model prediksi produktivitas padi berbasis *UAV* multispektral dengan pendekatan *Support Vector Regression (SVR)* yang dioptimasi menggunakan *grid search*. Penelitian ini diharapkan dapat memberikan kontribusi nyata dalam peningkatan akurasi prediksi hasil pertanian, khususnya di wilayah urban yang mengalami tekanan alih fungsi lahan.

METODE PENELITIAN
Waktu dan Lokasi Penelitian

Penelitian dilaksanakan pada tahun 2023 di Kelurahan Balumbang Jaya, Kecamatan Bogor Barat, Kota Bogor, pada koordinat 6°33'49.98" LS dan 106°44'11.47" BT. Lokasi ini dipilih secara purposif karena memiliki karakteristik lahan pertanian urban dengan dinamika penggunaan lahan yang kompleks. Selain itu, kondisi topografi yang relatif datar dan keterbukaan area lapang memungkinkan akuisisi data menggunakan *UAV* multispektral.

Alat dan Bahan

Perangkat lunak yang digunakan meliputi *ArcGIS* versi 10.4 untuk pengolahan data spasial, *RStudio* untuk analisis statistik dan *machine learning*, serta *Microsoft Excel* dan *Ms. Word* untuk manajemen data dan dokumentasi. Data citra multispektral diperoleh menggunakan *UAV DJI Phantom 4 Multispectral*. Spesifikasi teknis *UAV* disajikan pada Tabel 1 berikut:

Tabel 1. Spesifikasi *DJI Phantom 4 Multispectral*

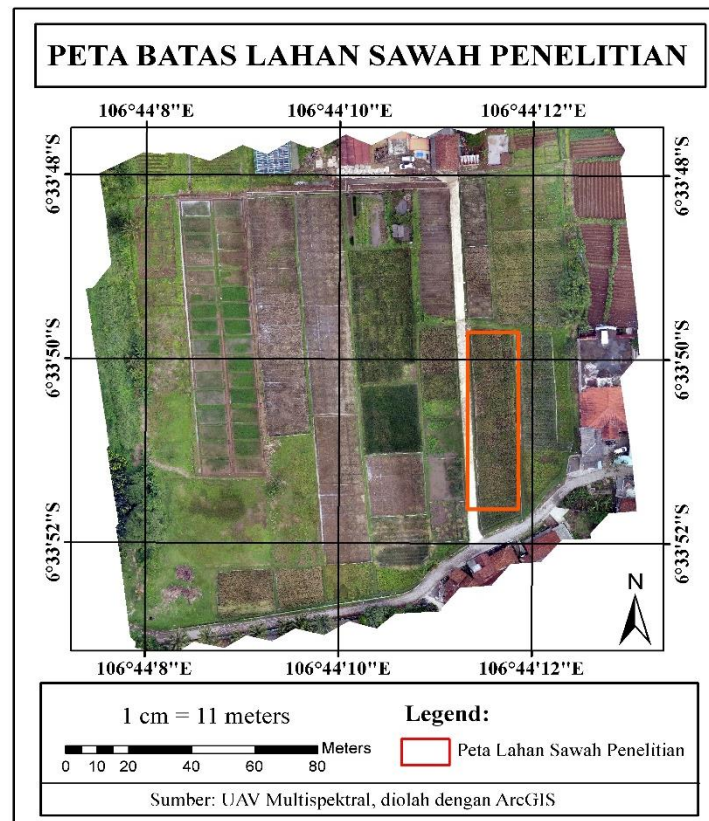
Spesifikasi	Nilai/Detail
Model <i>UAV</i>	<i>DJI Phantom 4 Multispectral</i>
Resolusi Spasial (GSD)	±2.74 cm/pixel pada ketinggian 60 m
Resolusi Spektral	5 band: <i>Blue, Green, Red, Red Edge, NIR</i>
Kamera RGB	12 MP
Akurasi Posisi (RTK)	±1 cm horizontal, ±1,5 cm vertical
Format Data	TIFF, JPEG, EXIF

Jenis Penelitian

Penelitian ini merupakan penelitian kuantitatif deskriptif dengan pendekatan analisis spasial dan *machine learning*. Tujuan utamanya adalah membangun dan memvalidasi model prediksi produktivitas padi berbasis indeks vegetasi dari citra *UAV* multispektral menggunakan metode *Support Vector Regression (SVR)*.

Metode Pengumpulan Data

Tahap pengumpulan data dilakukan secara komprehensif dengan mengintegrasikan data spasial dan non-spasial. Data spasial mencakup peta vektor batas lahan sawah dan citra multispektral hasil akuisisi *UAV*. Penelitian menggunakan 30 plot lahan berukuran 2,5x5 meter, yang dipilih secara purposif untuk mempresentasikan variasi spasial dari kondisi tanaman, termasuk tingkat kehijauan, kerapatan, dan pola tanam. Distribusi petak sawah disajikan pada Gambar 1.



Gambar 1. Peta Batas Lahan Sawah Lokasi Penelitian

Metode Analisis Data

Penelitian ini mengadopsi pendekatan metodologis integratif yang menggabungkan teknologi penginderaan jauh, analisis indeks vegetasi, dan machine learning untuk membangun model prediksi produktivitas padi. Pendekatan ini juga memberikan dasar empiris bagi strategi pengelolaan lahan yang berkelanjutan. Rangkaian metode disajikan dalam Gambar 2.

Pengolahan data dilakukan melalui tahapan sistematis menggunakan *RStudio*, dimulai dari ekstraksi nilai indeks vegetasi berdasarkan sel raster pada poligon tiap petak sawah. Untuk mengatasi ketidakseimbangan data pada tahap awal, digunakan teknik *Synthetic Minority Over-sampling Technique (SMOTE)* yang diterapkan terbatas pada data target yang telah diklasifikasi menjadi dua kelas (produktivitas tinggi dan rendah), dengan

tujuan menyeimbangkan distribusi kelas (Irawan et al., 2024).

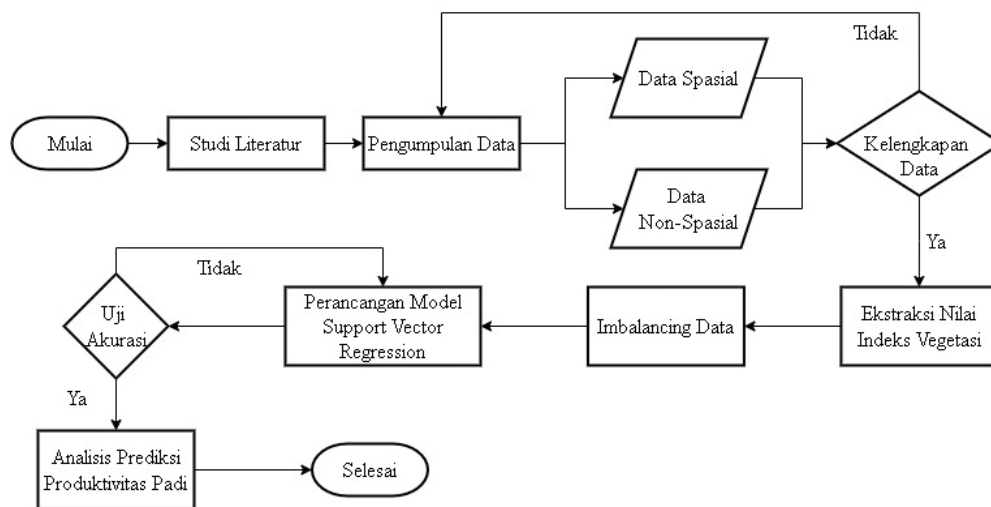
Model prediksi utama dibangun menggunakan algoritma *Support Vector Regression (SVR)*, yang bekerja dengan mencari fungsi $f(x) = \omega \cdot x + b$ yang meminimalkan kompleksitas model dan hanya mempertimbangkan *Support Vectors*, yaitu titik data yang berada di luar margin toleransi ϵ (Rahmawati et al., 2024). *SVR* unggul dalam menangani hubungan non-linear antara variabel input dan target, terutama dengan dukungan fungsi kernel.

Penelitian ini menggunakan kernel *Radial Basis Function (RBF)* yang mampu memproyeksikan data ke ruang berdimensi tinggi untuk mengungkapkan pola non-linear secara efektif (Bak et al., 2025). Parameter utama *SVR* yang dioptimalkan meliputi C (regulasi), ϵ (epsilon toleransi error), dan γ (gamma pada kernel *RBF*).

Optimasi parameter dilakukan melalui metode *grid search*, yang menguji kombinasi nilai secara sistematis dan dievaluasi dengan validasi silang *5-fold*. Konfigurasi terbaik dipilih berdasarkan nilai *Root Mean Square Error (RMSE)* terendah (Carracelas et al., 2024).

Kinerja model dievaluasi menggunakan menggunakan metrik statistik komprehensif, termasuk *RMSE*,

Mean Absolute Error (MAE), dan koefisien determinasi (R^2). Dataset dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian secara acak, namun dengan mempertimbangkan representasi spasial untuk mencerminkan sebaran geografis yang merata dan mencegah bias lokasi.



Gambar 2. Diagram Alir Penelitian

HASIL DAN PEMBAHASAN

Pengolahan Data

Proses pengolahan data dalam penelitian ini diawali dengan ekstraksi dan perhitungan indeks vegetasi, yang merupakan tahap kritis dalam analisis produktivitas padi menggunakan citra penginderaan jauh. Indeks vegetasi merupakan transformasi matematis dari beberapa pita spektral yang dirancang untuk mengoptimalkan informasi tanaman hijau, memungkinkan peneliti untuk menganalisis kondisi dan kesehatan tanaman secara kuantitatif (Kolang et al., 2024). Dalam penelitian ini, lima indeks vegetasi utama digunakan: *Normalized Difference Vegetation Index (NDVI)*, *Green Normalized Difference Vegetation Index (GNDVI)*, *Normalized Difference*

Red Edge (NDRE), *Optimized Soil-Adjusted Vegetation Index (OSAVI)*, dan *Leaf Chlorophyll Index (LCI)*.

Proses ekstraksi indeks vegetasi dilakukan menggunakan perangkat lunak *Rstudio*, dengan penarikan nilai sel raster berdasarkan fitur petak sawah. Setiap indeks vegetasi memiliki karakteristik unik dalam menggambarkan kondisi tanaman. *NDVI*, sebagai indeks paling umum digunakan, mengukur perbedaan antara pita merah dan *near-infrared* untuk menilai kepadatan dan kesehatan vegetasi. Sementara itu, *GNDVI* lebih sensitif terhadap variasi klorofil, memberikan informasi lebih mendalam tentang status nitrogen tanaman. *NDRE* fokus pada pita *red-edge*, memberikan penilaian lebih

presisi pada fase pertumbuhan tanaman yang lebih lanjut.

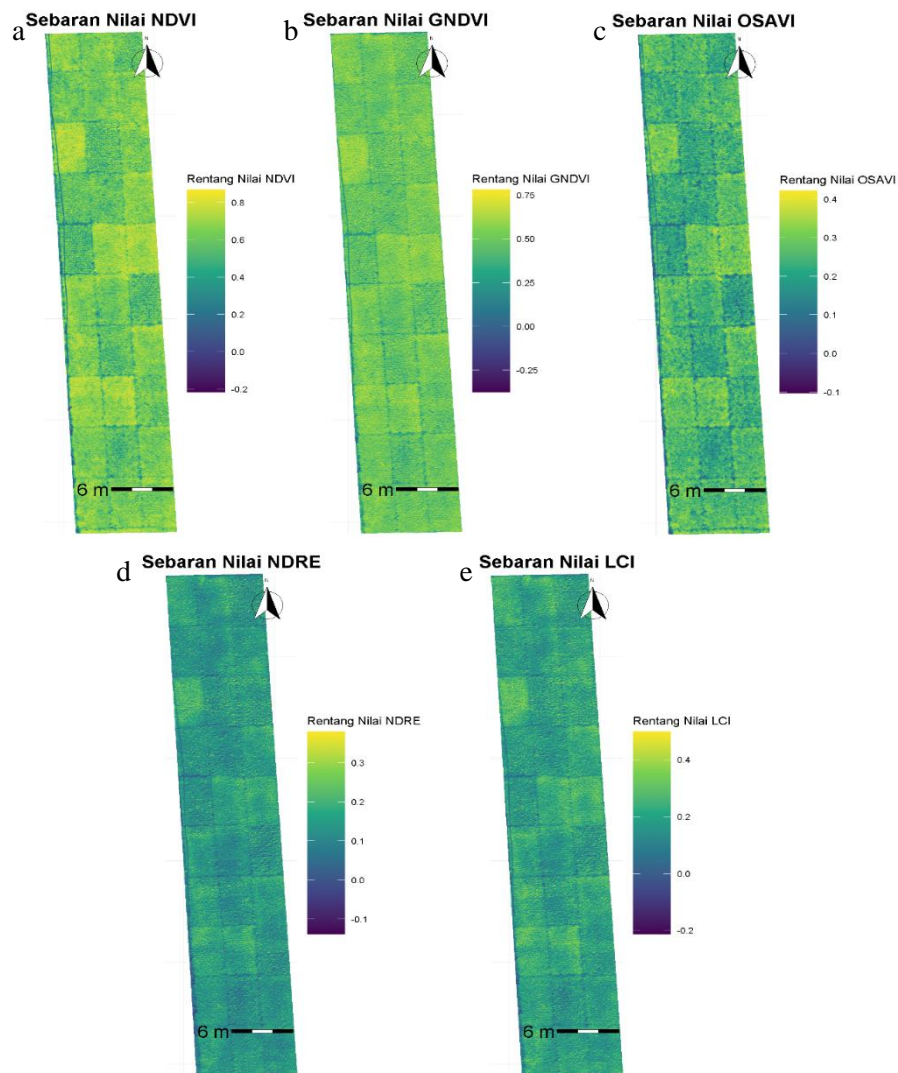
Perhitungan indeks vegetasi melibatkan serangkaian algoritma kompleks yang memproses data citra satelit dengan resolusi spasial tinggi. Setiap piksel citra ditransformasi menggunakan rumus spesifik untuk masing-masing indeks. Misalnya, *NDVI* dihitung menggunakan formula 1.

$$(NIR - Red) / (NIR + Red) \quad (1)$$

di mana *NIR* mewakili pantulan *near-infrared* dan *Red* mewakili pantulan pita merah. Proses ini menghasilkan nilai indeks antara -1 hingga 1, dengan nilai lebih tinggi mengindikasikan vegetasi

yang lebih sehat dan lebih rapat. Pemetaan sebaran indeks vegetasi dilakukan melalui analisis spasial yang komprehensif.

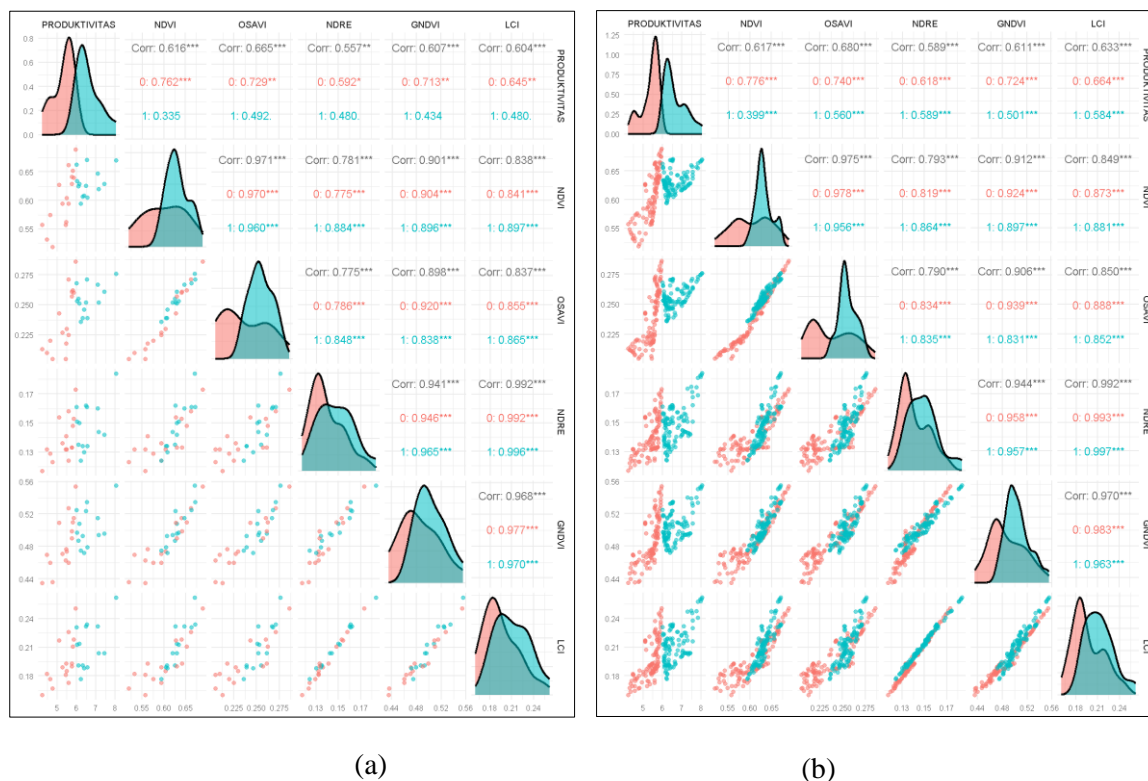
Hasil ekstraksi nilai indeks pada area penelitian menunjukkan variabilitas spasial yang signifikan, dengan kisaran sebagai berikut: *NDVI* (0,519-0,689), *OSAVI* (0,205-0,286), *NDRE* (0,117-0,184), *GNDVI* (0,435-0,555), dan *LCI* (0,160-0,262). Variasi ini divisualisasikan dalam peta tematik Gambar 3 dan mencerminkan heterogenitas kondisi tanaman akibat perbedaan mikroiklim, manajemen budidaya, atau kesuburan tanah.



Gambar 3. Peta Sebaran Nilai Indeks Vegetasi

Preprocessing data merupakan tahap kritis selanjutnya, dengan fokus utama pada mengatasi ketidakseimbangan kelas. Teknik *Synthetic Minority Over-sampling Technique (SMOTE)* diimplementasikan untuk menyelesaikan masalah distribusi data yang tidak

seimbang. Sebelum *SMOTE*, dataset memiliki 14 sampel kelas "1" (sesuai target produktivitas) dan 16 sampel kelas "0" (tidak sesuai target). Setelah penerapan *SMOTE*, kedua kelas diseimbangkan menjadi 112 sampel masing-masing. Visualisasi pada Gambar 4.



Gambar 4. Korelasi antara Indeks Vegetasi dan Produktivitas, Sebelum *SMOTE*, (b) Setelah *SMOTE*

Visualisasi distribusi data sebelum dan sesudah penerapan *SMOTE* menunjukkan perubahan signifikan pada sebaran nilai fitur tertentu, khususnya pada kelas produktivitas rendah yang sebelumnya sangat terbatas. Penambahan data sintesis dari *SMOTE* berhasil meningkatkan keseimbangan antar kelas dan memperbaiki distribusi input pada fase awal pelatihan model. Namun demikian, penggunaan data sintesis tetap menyimpan potensi resiko distorsi terhadap karakteristik asli data, terutama jika distribusi awal sangat tidak merata. Oleh karena itu, interpretasi hasil prediksi dilakukan dengan kehati-hatian, dan hasil

evaluasi regresi hanya mempertimbangkan data aktual tanpa menyertakan data sintetik *SMOTE*. Dengan pendekatan ini, integritas model regresi tetap terjaga dan tetap valid secara ilmiah.

Proses pengolahan data indeks vegetasi memerlukan analisis yang lebih mendalam mengenai kompleksitas hubungan antara indikator spektral dan produktivitas tanaman padi. Setiap indeks vegetasi yang digunakan memiliki mekanisme unik dalam menggambarkan dinamika pertumbuhan tanaman, yang melampaui sekadar pengukuran matematis sederhana. Misalnya, variasi spektral yang terekam melalui indeks vegetasi tidak

hanya mencerminkan kondisi fisik tanaman, tetapi juga mengandung informasi implisit tentang kesehatan fisiologis, status nutrisi, dan potensi produktivitas. Tahap lanjutan dalam analisis membutuhkan pendekatan komprehensif yang mempertimbangkan variabilitas spasial dan temporal dari berbagai parameter pertumbuhan.

Hasil analisis menunjukkan korelasi positif antara semua indeks vegetasi dengan produktivitas padi. *NDVI* dan *OSAVI* memiliki nilai korelasi tinggi, masing-masing $r=0,79$ dan $r=0,76$. Korelasi ini dapat dijelaskan secara ekologis: *NDVI* dan *OSAVI* berkorelasi dengan akumulasi biomassa, *GNDVI* dan *LCI* sensitif terhadap kandungan klorofil dan nitrogen, sedangkan *NDRE* efektif untuk menangkap perubahan fisiologis pada fase pengisian bulir (Bak et al., 2025; Carracelas et al., 2024). Hubungan ini mencerminkan keterkaitan antara struktur tanaman dan pantulan spektral yang ditangkap oleh sensor *UAV*.

Setiap indeks memiliki sensitivitas yang berbeda terhadap parameter tanaman. *NDVI*, misalnya, sangat berguna pada fase awal pertumbuhan, sementara *NDRE* lebih efektif dalam menganalisis fase pertumbuhan lanjut di mana struktur daun dan kandungan klorofil mengalami perubahan signifikan. *GNDVI* memberikan wawasan mendalam tentang dinamika nitrogen, yang secara langsung mempengaruhi kemampuan fotosintesis dan produktivitas tanaman. Kompleksitas analisis semakin meningkat ketika mempertimbangkan variabilitas spasial yang tercermin dalam rentang nilai indeks vegetasi. Variasi antara 0,519-0,689 untuk *NDVI* dan 0,435-0,555 untuk *GNDVI* mengindikasikan heterogenitas spasial yang signifikan dalam kondisi tanaman.

Implementasi teknik *SMOTE* (*Synthetic Minority Over-sampling Technique*) dalam preprocessing data menjadi strategi kritis untuk mengatasi

keterbatasan dataset. Proses ini tidak sekadar menambah jumlah sampel, tetapi menciptakan ruang fitur baru yang memungkinkan model *machine learning* memahami pola-pola tersembunyi dalam dataset. Dengan mensintesis sampel baru berdasarkan kedekatan dalam ruang fitur multidimensi, *SMOTE* membangun jembatan antara keterbatasan data empiris dan kompleksitas fenomena pertanian.

Pendekatan multidisipliner dalam penelitian ini mencerminkan evolusi metodologi analisis pertanian modern. Integrasi antara penginderaan jauh, analisis citra, dan *machine learning* membuka paradigma baru dalam memahami dinamika pertumbuhan tanaman. Tidak lagi sekadar mengumpulkan data, tetapi mengubah data menjadi pengetahuan yang dapat digunakan untuk membuat keputusan strategis dalam manajemen pertanian presisi. Signifikansi metodologi yang dikembangkan terletak pada kemampuannya untuk mentransformasi data spektral menjadi wawasan prediktif tentang produktivitas tanaman. Setiap indeks vegetasi yang dianalisis tidak hanya memberikan potret seketika kondisi tanaman, tetapi juga menawarkan jendela untuk memahami trajektori pertumbuhan, mengidentifikasi potensi stres tanaman, dan meramalkan luaran produktif dengan tingkat akurasi yang lebih tinggi dibandingkan metode konvensional.

Dengan demikian, pengolahan data indeks vegetasi dalam konteks analisis produktivitas padi bukan sekadar proses teknis, melainkan representasi kompleks dari interaksi antara teknologi, pertanian, dan pemahaman ilmiah tentang dinamika ekosistem tanaman. Setiap langkah dalam metodologi ini membawa kita lebih dekat pada kemampuan untuk memahami, memprediksi, dan akhirnya mengoptimalkan produktivitas tanaman padi dalam konteks pertanian modern yang semakin kompleks.

Pemodelan dan Evaluasi Hasil Prediksi SVR

Pemodelan *Support Vector Regression (SVR)* merupakan pendekatan *machine learning* canggih yang digunakan untuk menganalisis produktivitas padi melalui pendekatan regresi non-linear dengan kernel *Radial Basis Function (RBF)*. Metode ini dipilih karena kemampuannya menangani kompleksitas hubungan antara indeks vegetasi dan produktivitas padi yang bersifat non-linear dan memiliki interaksi kompleks antar variabel (Masdian et al., 2023). Implementasi *SVR* dengan kernel *RBF* dimulai dengan transformasi ruang fitur input ke dimensi yang lebih tinggi, memungkinkan model menangkap pola non-linear yang kompleks dalam dataset. Kernel *RBF* memiliki keunggulan dalam mengakomodasi variasi spasial dan temporal yang signifikan pada data pertanian, khususnya dalam konteks analisis produktivitas padi. Fungsi kernel *RBF* didefinisikan sebagai Persamaan 2.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2)$$

di mana γ merupakan parameter kunci yang mengontrol kompleksitas transformasi ruang fitur.

Proses optimasi parameter menggunakan *grid search* merupakan tahap kritis dalam mengembangkan model *SVR* yang optimal. Dalam penelitian ini, dua parameter utama dioptimasi: *Cost* (C) dan *sigma* (σ). Rentang nilai yang dieksplorasi meliputi C: [0.1, 1, 10] dan σ : [0.1, 1, 10]. *Grid search* dilakukan dengan metode *exhaustive search*, mengevaluasi setiap kombinasi parameter untuk menemukan konfigurasi yang memberikan performa prediksi terbaik. Meskipun model *SVR* menunjukkan performa yang tinggi, perlu dicatat bahwa risiko *overfitting* tetap menjadi perhatian utama, mengingat jumlah data yang terbatas dan kompleksitas model yang tinggi. Oleh

karena itu, penelitian ini menerapkan strategi validasi silang (*5-fold cross-validation*) dan pengujian sistematis terhadap kombinasi parameter (*grid search*) untuk mengurangi risiko *overfitting* dan memastikan generalisasi model. Penggunaan regulasi melalui parameter C dan kontrol margin melalui *epsilon* turut membantu membatasi kompleksitas model. Hasil validasi silang menghasilkan model dengan parameter optimal: *sigma*=1 dan *cost*=1 dapat dilihat pada Gambar 5.

Support Vector Machines with Radial Basis Function Kernel

224 samples
5 predictor

Pre-processing: centered (5), scaled (5)
Resampling: Cross-Validated (5 fold)
Summary of sample sizes: 179, 179, 179, 179, 180
Resampling results across tuning parameters:

sigma	C	RMSE	Rsquared	MAE
0.1	0.1	0.6065633	0.5287521	0.4723696
0.1	0.2	0.5536185	0.6122417	0.4343430
0.1	0.3	0.5158635	0.6583133	0.4075751
0.1	0.4	0.4970016	0.6813355	0.3898952
0.1	0.5	0.4798145	0.6951056	0.3743538
0.1	0.6	0.4673127	0.7052127	0.3617759
0.1	0.7	0.4595451	0.7140432	0.3553976
0.1	0.8	0.4502027	0.7244178	0.3493527
0.1	0.9	0.4435446	0.7319227	0.3434196
0.1	1.0	0.4363866	0.7411069	0.3386161
0.2	0.1	0.5874702	0.5739041	0.4475217
0.2	0.2	0.5214589	0.6612942	0.3993174
0.2	0.3	0.4818378	0.7000074	0.3712210
0.2	0.4	0.4507845	0.7276351	0.3495166
0.2	0.5	0.4346739	0.7451233	0.3367411
0.2	0.6	0.4201372	0.7614188	0.3251404
0.2	0.7	0.4080040	0.7735577	0.3151143
0.2	0.8	0.3990751	0.7834541	0.3075255
0.2	0.9	0.3902741	0.7933642	0.3011708
0.2	1.0	0.3815828	0.8018195	0.2950733
0.3	0.1	0.5819274	0.6016391	0.4375869
0.8	0.7	0.3262459	0.8577678	0.2431698
0.8	0.8	0.3183795	0.8631706	0.2358197
0.8	0.9	0.3120758	0.8675360	0.2295837
0.8	1.0	0.3060990	0.8711771	0.2235784
0.9	0.1	0.5847032	0.6587083	0.4333143
0.9	0.2	0.4743149	0.7636644	0.3538291
0.9	0.3	0.4041462	0.8126126	0.3074776
0.9	0.4	0.3664759	0.8347951	0.2785633
0.9	0.5	0.3450466	0.8471503	0.2598002
0.9	0.6	0.3335582	0.8540519	0.2482950
0.9	0.7	0.3225480	0.8611727	0.2381527
0.9	0.8	0.3155452	0.8658750	0.2316129
0.9	0.9	0.3076806	0.8709455	0.2244282
0.9	1.0	0.3022149	0.8736743	0.2186598
1.0	0.1	0.5883779	0.6592402	0.4346793
1.0	0.2	0.4744120	0.7685424	0.3531700
1.0	0.3	0.4030197	0.8157411	0.3058273
1.0	0.4	0.3643760	0.8375502	0.2763117
1.0	0.5	0.3432521	0.8498494	0.2573892
1.0	0.6	0.3314528	0.8570199	0.2457719
1.0	0.7	0.3208102	0.8629759	0.2358797
1.0	0.8	0.3122323	0.8684683	0.2282280
1.0	0.9	0.3048101	0.8726474	0.2212227
1.0	1.0	0.2989805	0.8760373	0.2152744

RMSE was used to select the optimal model using the smallest value.
The final values used for the model were sigma = 1 and C = 1.

Gambar 5. Hasil Pemodelan SVR Menggunakan *GridsearchCV*

Model *SVR* yang dikembangkan mendemonstrasikan potensi signifikan *machine learning* dalam memprediksi produktivitas padi berdasarkan indeks vegetasi, menyediakan pendekatan inovatif untuk mendukung keputusan pertanian presisi. Eksplorasi lebih lanjut terhadap mekanisme *Support Vector Regression (SVR)* mengungkapkan kompleksitas fundamental dalam pendekatan *machine learning* untuk prediksi produktivitas pertanian. Metode *SVR* tidak sekadar algoritma komputasi, melainkan representasi matematis dari interaksi kompleks antara variabel lingkungan, karakteristik tanaman, dan potensi produktivitas. Transformasi ruang fitur melalui kernel *Radial Basis Function (RBF)* membuka dimensi baru dalam memahami hubungan non-linear yang sebelumnya sulit dikuantifikasi menggunakan metode statistik konvensional.

Signifikansi metodologis *SVR* terletak pada kemampuannya mengatasi tantangan fundamental dalam memodelkan sistem pertanian. Pertanian merupakan sistem kompleks dengan variabilitas tinggi, di mana setiap faktor berinteraksi secara dinamis dan tidak linear. Kernel *RBF* bertindak sebagai mekanisme adaptif yang mampu menangkap nuansa halus dalam relasi antar variabel, melampaui pendekatan linier tradisional yang cenderung menyederhanakan realitas kompleks pertumbuhan tanaman. Proses optimasi parameter melalui *grid search* mencerminkan pendekatan sistematis dalam mengonstruksi model prediktif yang andal.

Eksplorasi rentang nilai *Cost (C)* dan *sigma (σ)* bukanlah sekadar latihan komputasional, melainkan upaya metodologis untuk mengeksplorasi batas-batas kemampuan model dalam menggeneralisasi pola tersembunyi dalam dataset. Setiap iterasi *grid search*

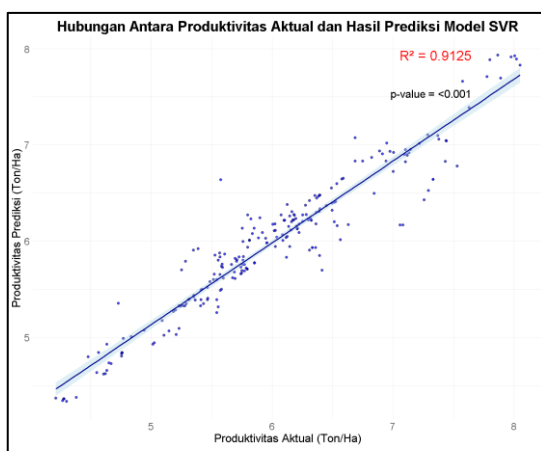
berpotensi mengungkap hubungan yang sebelumnya tidak terdeteksi antara indeks vegetasi dan produktivitas tanaman. Validasi silang *5-fold* yang diimplementasikan memiliki peran kritis dalam membangun kepercayaan terhadap model. Metode ini tidak hanya sekadar teknik statistik, tetapi representasi filosofis dari keraguan ilmiah yang konstruktif. Dengan membagi data ke dalam subset independen dan menguji model pada berbagai kombinasi data latih dan validasi, peneliti mengembangkan model yang robust dan dapat dipercaya, mengurangi risiko *overfitting* yang selama ini menjadi tantangan utama dalam pemodelan *machine learning*.

Metrik evaluasi model mencakup *R-squared (R^2)* dan *Root Mean Squared Error (RMSE)*. Dalam penelitian ini, model *SVR* mencapai R^2 sebesar 0,876, mengindikasikan bahwa 87,6% variasi produktivitas padi dapat dijelaskan oleh model menggunakan indeks vegetasi. *RMSE* sebesar 0,29 ton/ha menunjukkan tingkat kesalahan prediksi yang relatif rendah, mengonfirmasi akurasi model yang tinggi (Tamara et al., 2021).

Setelah dilakukan pelatihan model *SVR* menggunakan data hasil ekstraksi indeks vegetasi, diperoleh hasil prediksi awal produktivitas padi. Visualisasi awal hubungan antara nilai prediksi dan aktual disajikan pada Gambar 6 untuk memberikan gambaran pola distribusi hasil prediksi.

Capaian *R-squared* sebesar 0,876 mengindikasikan lebih dari sekadar keberhasilan matematis. Angka ini menggambarkan kemampuan model untuk menjelaskan variasi kompleks dalam produktivitas padi, mentransformasi data mentah menjadi wawasan prediktif yang bermakna. Setiap persentase peningkatan *R-squared* berpotensi memberikan kontribusi signifikan dalam pemahaman dinamika pertumbuhan tanaman dan strategi optimasi produktivitas. *Root Mean*

Squared Error (RMSE) sebesar 0,29 ton/ha tidak sekadar metrik statistik, melainkan jendela untuk memahami batas-batas prediksi ilmiah. Tingkat kesalahan yang rendah ini menunjukkan bahwa model *SVR* mampu mengidentifikasi pola fundamental dalam hubungan antara indeks vegetasi dan produktivitas dengan presisi yang mengagumkan. Setiap ton per hektar dalam prediksi berpotensi memiliki implikasi ekonomi dan sosial yang substansial bagi petani dan sistem pangan.

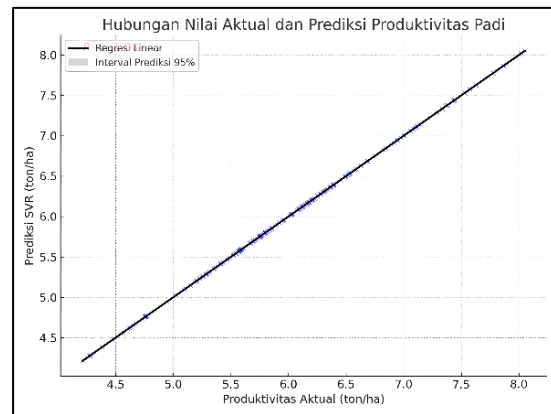


Gambar 6. Grafik Hubungan Awal antara Nilai Produktivitas Aktual dan Hasil Prediksi Model SVR

Analisis hasil prediksi produktivitas padi menggunakan *Support Vector Regression (SVR)* mengungkapkan kompleksitas hubungan antara indeks vegetasi dan hasil panen. Model ini mencapai koefisien determinasi (R^2) sebesar 0,876 yang menunjukkan bahwa 87,6% variabilitas produktivitas padi dapat dijelaskan oleh parameter indeks vegetasi seperti *NDVI*, *GNDVI*, *NDRE*, *OSAVI* dan *LCI* (Marsuhandi et al., 2020).

Nilai *Root Mean Squared Error (RMSE)* sebesar 0,29 ton/ha mengindikasikan tingkat kesalahan prediksi yang rendah, sehingga mengkonfirmasi keandalan model dalam memperkirakan hasil panen secara akurat. Untuk mengevaluasi akurasi model secara menyeluruh, dilakukan analisis visual

ambahan dengan memasukkan *Prediction Interval 95%* pada hasil prediksi. Visualisasi ini disajikan pada Gambar 7 dan digunakan untuk menggambarkan ketidakpastian estimasi individual dan model regresi.



Gambar 7. Grafik Prediksi Produktivitas Padi dilengkapi dengan Garis Regresi dan *Prediction Interval 95%*

Garis regresi linear disertai pita interval prediksi 95% menunjukkan bahwa sebagian besar titik data berada dalam rentang prediksi yang dapat diterima. Hal ini menegaskan bahwa model *SVR* tidak hanya memiliki akurasi tinggi, tetapi juga stabil secara prediktif, dengan tingkat ketidakpastian yang tinggi.

Pendekatan *SVR* dalam penelitian ini tidak hanya menghadirkan akurasi tinggi secara statistik, tetapi juga membuka paradigma baru dalam pertanian presisi. Di era konvergensi teknologi penginderaan jauh dan *machine learning*, model tidak lagi dipandang sebagai alat prediksi semata, melainkan sistem pembelajaran adaptif yang mampu menyesuaikan diri dengan kompleksitas sistem pertanian. Hal ini menjadi dasar untuk memahami lebih dalam bagaimana setiap indeks vegetasi berkontribusi secara unik terhadap produktivitas tanaman.

Analisis mendalam terhadap indeks vegetasi dengan produktivitas menunjukkan bahwa setiap indeks vegetasi memiliki peran diagnostik tersendiri dalam memprediksi

produktivitas. *NDVI* menunjukkan korelasi signifikan dengan biomassa tanaman, sementara *GNDVI* memberikan informasi lebih spesifik tentang status nitrogen. *NDRE* memperlihatkan sensitivitas tinggi terhadap perubahan kondisi tanaman pada fase pertumbuhan lanjut, yang sangat kritis dalam memprediksi produktivitas akhir (Nadzirah et al., 2022).

Rentang nilai indeks seperti *OSAVI* yang berkisar 0,205-0,286 dan *NDVI* 0,519-0,689 mengindikasikan heterogenitas spasial lahan pertanian. Temuan dalam penelitian ini menguatkan hasil studi (Bak et al., 2025) yang menunjukkan bahwa indeks vegetasi berbasis *NIR* seperti *NDVI* dan *GNDVI* memiliki hubungan signifikan dengan produktivitas padi pada tingkat kanopi. Hal ini juga sejalan dengan penelitian (Carracelas et al., 2024) yang menegaskan efektivitas penginderaan jauh berbasis *UAV* dalam memantau status nitrogen tanaman padi, khususnya melalui indeks *GNDVI*. Lebih lanjut, pemanfaatan teknik *SMOTE* dalam tahap prapemodelan untuk mengatasi ketidakseimbangan data telah diimplementasikan secara efektif oleh (Irawan et al., 2024) dalam konteks pemodelan data pertanian. Penelitian ini juga melengkapi temuan (Ariani et al., 2020) yang memanfaatkan *NDVI* dan citra multitemporal Sentinel-2 untuk estimasi produktivitas padi, dengan menambahkan aspek integrasi *machine learning SVR* dan pendekatan prediksi berbasis *UAV* multispektral dalam konteks lahan sawah perkotaan.

KESIMPULAN

Penelitian ini memberikan kontribusi signifikan dalam bidang pertanian presisi melalui pengembangan model prediksi produktivitas padi berbasis citra *UAV* multispektral dan algoritma *Support Vector Regression (SVR)*. Integrasi penginderaan jauh dan machine

learning menunjukkan potensi pendekatan multidisipliner dalam memahami dinamika pertumbuhan tanaman. Model *SVR* yang dikembangkan mampu menjelaskan 87,6% variabilitas produktivitas padi dengan tingkat kesalahan prediksi rendah (*RMSE* 0,29 ton/ha), mencerminkan keandalan model dalam memperkirakan hasil panen.

Lima indeks vegetasi yang digunakan - *NDVI*, *GNDVI*, *NDRE*, *OSAVI*, dan *LCI* - memberikan perspektif komprehensif terhadap status fisiologis tanaman dan terbukti berkorelasi erat dengan produktivitas padi. Teknik *Synthetic Minority Over-sampling Technique (SMOTE)* digunakan secara terbatas untuk menyeimbangkan data pada tahap klasifikasi awal, bukan dalam proses regresi, sehingga tidak memengaruhi validitas prediksi. Model dievaluasi secara ketat menggunakan validasi silang dan visualisasi prediktif lengkap dengan *prediction interval* 95%, memastikan stabilitas dan keandalan estimasi. Pendekatan ini tidak hanya menghasilkan model prediktif akurat, tetapi juga membuka paradigma baru dalam pengembang strategi pengelolaan lahan berbasis data. Metodologi yang diperkenalkan dapat menjadi fondasi bagi penelitian lanjutan dari bidang pertanian presisi, mendukung pengambilan keputusan strategis yang adaptif terhadap dinamika lingkungan dan tantangan ketahanan pangan global.

DAFTAR PUSTAKA

Ariani, D., Prasetyo, Y., & Sasmito, B. (2020). Estimasi Tingkat Produktivitas Padi Berdasarkan Algoritma *NDVI*, *EVI* dan *SAVI* Menggunakan Citra Sentinel-2 Multitemporal (Studi Kasus: Kabupaten Pekalongan, Jawa Tengah). In *Jurnal Geodesi Undip Januari* (Issue 9).

- Bak, H. J., Kim, E. J., Lee, J. H., Chang, S., Kwon, D., Im, W. J., Kim, D. H., Lee, I. H., Lee, M. J., Hwang, W. H., Chung, N. J., & Sang, W. G. (2025). Canopy-Level Rice Yield and Yield Component Estimation Using NIR-Based Vegetation Indices. *Agriculture (Switzerland)*, 15(6). <https://doi.org/10.3390/agriculture15060594>
- Bappeda Kota Bogor. (2023). *Laporan Evaluasi RT/RW dan Perubahan Penggunaan Lahan 2018–2023*.
- Carracelas, G., Ballester, C., Marchesi, C., Roel, A., & Hornbuckle, J. (2024). Assessing Drone-Based Remote Sensing Indices for Monitoring Rice Nitrogen Plant Status Under Different Irrigation Techniques. *Agronomy*, 14(12). <https://doi.org/10.3390/agronomy14122976>
- Fajri, Z. A., Sanjoto, T. B., Akhsin, W., Nur, B., & Infra, N. (2022). Model Estimasi Produktivitas Padi Menggunakan NDVI di Wilayah Kabupaten Demak Tahun 2021. 8(3), 279–289.
- Gandhi, P., & Darmawan, I. (2022). Persepsi Kelompok Tani Terhadap Multifungsi Sawah Dan Strategi Keberlanjutan Kebijakan PLP2B Di Kota Bogor. 21(16).
- Irawan, Y., Wahyuni, R., & Ordila, R. (2024). Comparative Analysis of Machine Learning Algorithms with SMOTE and Boosting Techniques in Accuracy Improvement. *The Indonesian Journal of Computer Science*, 13(5). <https://doi.org/10.33022/ijcs.v13i5.4386>
- Jannah, A., Rosyad, A., Masnang, A., Anggarawati, S., Arifien, Y., Wibaningwati, D. B., Fitriani, A., Maad, F., Rosiana, A., Febrian, R., Bakri, A., & Jono, M. (2020). Pemberdayaan Wanita Tani dalam Penyediaan Benih untuk Mendukung Urban Farming di Kelurahan Balumbang Jaya , Empowerment Of Farming Women In Providing Seeds To Support Urban Farming In Balumbang Jaya Village , Bogor City. 5(2), 169–174.
- Komang, N., Mita, A., Siddiq, M. F., Laurnt, A., Erviana, R., & Kurniawan, R. (2024). Optimalisasi Ketahanan Pangan : Perbandingan Metode Machine Learning dan Time Series dalam Memprediksi Produksi Padi di Jawa Tengah. 2024(Senada), 140–153.
- Liu, S., Zeng, W., Wu, L., Lei, G., Chen, H., Gaiser, T., & Srivastava, A. K. (2021). Simulating the Leaf Area Index of Rice from Multispectral Images. *Remote Sensing*, 13(18), 1–22. <https://doi.org/10.3390/rs13183663>
- Liu, Z., Ju, H., Ma, Q., Sun, C., Lv, Y., Liu, K., Wu, T., & Cheng, M. (2024). Rice Yield Estimation Using Multi-Temporal Remote Sensing Data and Machine Learning: A Case Study of Jiangsu, China. *Agriculture (Switzerland)*, 14(4). <https://doi.org/10.3390/agriculture14040638>
- Marsuhandi, A. H., Soleh, A. M., Wijayanto, H., & Domiri, D. D. (2020). Pemanfaatan Ensemble Learning dan Penginderaan Jauh untuk Pengklasifikasian Jenis Lahan Padi. *Seminar Nasional Official Statistics*, 2019(1), 188–195. <https://doi.org/10.34123/semnasoffstat.v2019i1.247>
- Masdian, A. R., Bashit, N., & Hadi, F. (2023). Analisis Produktivitas Padi Menggunakan Algoritma Machine Learning Random Forest di Kabupaten Batang Tahun 2018 - 2022. *Elipsoida : Jurnal Geodesi Dan Geomatika*, 6(1), 43–51.

- <https://doi.org/10.14710/elipsoida.2023.19023>
- Nadzirah, R., Indarto, I., & Brillyansyah, D. F. (2022). Studi Pendahuluan Aplikasi Citra Sentinel untuk Deteksi Luas Sawah Irigasi di Kabupaten Jember. *Jurnal Ilmiah Rekayasa Pertanian Dan Biosistem*, 10(1), 24–38.
<https://doi.org/10.29303/jrpb.v10i1.319>
- Quille-Mamani, J., Ramos-Fernández, L., Huanuqueño-Murillo, J., Quispe-Tito, D., Cruz-Villacorta, L., Pino-Vargas, E., Flores del Pino, L., Heros-Aguilar, E., & Ángel Ruiz, L. (2025). Rice Yield Prediction Using Spectral and Textural Indices Derived from UAV Imagery and Machine Learning Models in Lambayeque, Peru. *Remote Sensing*, 17(4).
<https://doi.org/10.3390/rs17040632>
- Rahmawati, S., Wibowo, A., & Masruriyah, A. F. N. (2024). Improving Diabetes Prediction Accuracy in Indonesia: A Comparative Analysis of SVM, Logistic Regression, and Naive Bayes with SMOTE and ADASYN. *Jurnal RESTI*, 8(5), 607–614.
<https://doi.org/10.29207/resti.v8i5.5980>
- Sunito, Q. A. M. and M. A. (2019). Pengaruh Jenis Perubahan Fungsi Rumah terhadap Taraf Hidup dan Kondisi Sosial Budaya Masyarakat. *Departemen Sains Komunikasi Dan Pengembangan Masyarakat, Fakultas Ekologi Manusia, IPB, Vol 3*.
- Tamara, N., Wigena, A. H., & Sartono, B. (2021). Classification Model for Paddy Growth Phase Prediction with Machine Learning Based on Satellite Imagery. *Globë*, 23(2), 101–112.
- Wardana, K. P. W., Subiyanto, S., & Hani'ah. (2019). Analisis Tinggi Tanaman Padi Menggunakan Model 3D Hasil Pemotretan UAV dengan Pengukuran Lapangan. *Jurnal Geodesi UNDIP*, 8(1), 378–387.
- Yanuaireva, Z. T., Yanuar, M., & Purwanto, J. (2023). Kajian Luasan Petak Sawah untuk Perencanaan Konsolidasi Lahan Persawahan. 1(02), 113–120.
<https://doi.org/10.55180/aei.v1i2.727>