

GOOGLE EARTH ENGINE UNTUK ESTIMASI PRODUKSI PADI

GOOGLE EARTH ENGINE FOR ESTIMATING RICE PRODUCTION

Rio Valery Allen^{1*}, Muhammad Syahfitra², Romy Aulia³

¹ Program Studi Teknologi Mekanisasi Pertanian, Politeknik Pertanian Negeri Payakumbuh, Payakumbuh, Indonesia

² Program Studi Pengelolaan Perkebunan, Politeknik Pertanian Negeri Payakumbuh, Payakumbuh, Indonesia

³ Program Studi Teknologi Rekayasa Komputer, Politeknik Pertanian Negeri Payakumbuh, Payakumbuh, Indonesia

*Email Penulis korespondensi: Rioallen59@gmail.com

Abstrak

Peningkatan populasi global dan kompleksitas tantangan ketahanan pangan mendorong kebutuhan mendesak akan data produksi padi yang akurat, cepat, dan berskala besar. Penelitian ini mengevaluasi efektivitas platform *Google Earth Engine (GEE)* dalam mengintegrasikan data satelit dengan algoritma pembelajaran mesin untuk estimasi produksi padi. Metodologi berfokus pada pendekatan berbasis indeks vegetasi seperti NDVI, SAVI, ARVI dan model regresi linier sederhana. Metode ini berbasis kepada penggunaan teknologi *Cloud Computing* dan *Big Data* yang ada pada platform *Google Earth Engine (GEE)*. Penggunaan *Cloud Computing* dan *Big Data* seperti pada platform *Google Earth Engine (GEE)* membuat perolehan citra satelit seperti luas lahan sawah menjadi lebih cepat. Studi kasus di Kabupaten Sleman menunjukkan koefisien determinasi (R^2) yang sangat rendah. Hal ini mengindikasikan bahwa model berbasis indeks vegetasi linier hanya mampu menjelaskan sebagian kecil variabilitas produktivitas padi di lapangan. Temuan ini menekankan bahwa faktor-faktor lain seperti curah hujan dan struktur tanah, memainkan peran yang jauh lebih signifikan daripada indeks vegetasi saja. Meskipun GEE menawarkan solusi dalam mengatasi keterbatasan metode konvensional namun efektivitasnya sebagai alat estimasi yang akurat sangat bergantung pada pengembangan model yang lebih kompleks.

Kata kunci: Google Earth Engine, Produksi Padi, Indeks Vegetasi, Model Regresi, Ketahanan Pangan, Pertanian Presisi

Abstract

The growing global population and the complexity of food security challenges have created an urgent need for accurate, timely, and large-scale rice production data. This study evaluates the effectiveness of the Google Earth Engine (GEE) platform in integrating satellite data with machine learning algorithms for rice production estimation. The methodology focuses on vegetation index-based approaches such as NDVI, SAVI, ARVI, and simple linear regression models. This method relies on the use of Cloud Computing and Big Data technologies available on the Google Earth Engine (GEE) platform. The use of Cloud Computing and Big Data, as found on the Google Earth Engine (GEE) platform, enables the acquisition of satellite imagery—such as the area of rice fields—to be faster. A case study in Sleman Regency showed a very low coefficient of determination (R^2). This indicates that linear vegetation index-based models can only explain a small portion of the variability in rice productivity in the field. This finding emphasizes that other factors, such as rainfall and soil structure, play a far more significant role than vegetation indices alone. Although GEE offers a solution to the limitations of conventional methods, its effectiveness as an accurate estimation tool is highly dependent on the development of more complex models.

Keyword: Google Earth Engine, Rice Production, Vegetation Index, Regression Model, Food Security, Precision Agriculture

PENDAHULUAN

Krisis pangan global menjadi isu krusial karena permintaan pangan dunia diperkirakan akan meningkat antara 35% hingga 56% pada periode 2010-2050 (Van Dijk *et al.*, 2021). Padi merupakan komoditas strategis yang menghidupi lebih dari setengah

populasi dunia, namun produksinya terus terancam oleh penyusutan lahan produktif akibat urbanisasi dan fluktuasi iklim (Mueller *et al.*, 2012). Di Indonesia, pemerintah sangat bergantung pada data produksi yang akurat untuk menjaga stabilitas harga dan logistik pangan (Badan Pusat Statistik RI, 2018). Ketersediaan data produksi padi yang akurat dan tepat waktu merupakan pilar penting dalam menjaga ketahanan pangan nasional. Data ini menjadi dasar bagi pemerintah dan pemangku kepentingan untuk merumuskan kebijakan pertanian yang efektif, mulai dari alokasi pupuk hingga penentuan harga panen. Namun, seperti yang dicatat dalam laporan internal, produksi padi di Indonesia masih menghadapi tantangan signifikan. Sebagai contoh, data dari Kementerian Pertanian Republik Indonesia (2022) menunjukkan bahwa produksi padi pada tahun 2021 masih jauh di bawah target yang ditetapkan, mencapai 54,42 juta ton.

Secara historis, estimasi produksi padi dilakukan melalui metode konvensional, seperti survei lapangan dan laporan petani. Metode konvensional seperti Kerangka Sampel Area (KSA) memerlukan sumber daya manusia yang besar dan sering kali terhambat oleh kendala geografis (Gandharum *et al.*, 2021). Sebagai alternatif, teknologi penginderaan jauh menawarkan kemampuan pengamatan kontinu pada skala luas (Indarto, 2014). *Google Earth Engine* (GEE) telah mendemokrasi akses terhadap data satelit *petabyte*, memungkinkan pemrosesan data tanpa kendala infrastruktur lokal (Gorelick *et al.*, 2017). Platform ini menyediakan akses langsung ke koleksi Landsat, Sentinel-1, dan Sentinel-2 yang telah terkalibrasi (Inoue *et al.*, 2020). Melalui integrasi data multimodal dan kecerdasan buatan, GEE memungkinkan estimasi produksi padi dilakukan (Thorp & Drajat, 2021).

Dengan memantau kesehatan dan pertumbuhan tanaman secara terus-menerus sepanjang musim tanam, teknologi ini dapat memberikan peringatan dini mengenai potensi penurunan hasil, yang memungkinkan intervensi kebijakan yang lebih cepat dan tepat, seperti yang diperlukan untuk mengatasi tantangan yang telah diidentifikasi dalam menjaga luas lahan panen (Mooy *et al.*, 2023). Peralihan ini tidak hanya tentang adopsi alat baru, tetapi juga pergeseran fundamental dalam cara data pertanian dikumpulkan dan dimanfaatkan untuk manajemen sumber daya dan perencanaan strategis.

METODE PENELITIAN

Penelitian dilakukan pada bulan April – Juli tahun 2025 yang berlokasi di Kabupaten Sleman, Yogyakarta. Penelitian ini menggunakan alat dan bahan berupa laptop, ArcGIS 10.3, *Google Earth Engine*, Microsoft excel, serta alat pendukung lainnya. Bahan yang digunakan dalam penelitian ini adalah data Citra Satelit Landsat 8 OLI tahun 2015 dan tahun 2025. Metode yang digunakan dalam penelitian ini terdiri dari persiapan, pengolahan dan tahap analisis. Tahap pertama, yaitu persiapan meliputi studi literatur dan pengumpulan data. Literatur mencakup referensi pustaka yang berhubungan dengan penelitian. Pengumpulan data yang dibutuhkan dalam penelitian mulai dari citra dan batas wilayah kerja. Tahap kedua, yaitu pengolahan dari penelitian ini menggunakan bahasa pemrograman *javascript* yang tersedia di GEE, mulai dari *import data* Landsat 8, batas wilayah kerja dan dilakukan *cloud masking* pada citra untuk menghilangkan tutupan awan yang menutupi daerah penelitian lalu dilaksanakan tahap analisis berdasarkan data yang tersedia.

Prinsip Dasar Indeks Vegetasi

Prinsip dasar di balik estimasi produksi padi menggunakan penginderaan jauh terletak pada hubungan antara pantulan spektral tanaman dan kesehatannya. Tanaman hijau yang sehat memiliki karakteristik unik dalam cara mereka berinteraksi dengan

cahaya. Klorofil dalam daun menyerap sebagian besar radiasi cahaya merah (*Red*) untuk fotosintesis, sementara struktur sel mesofil pada daun memantulkan radiasi inframerah dekat (NIR) dengan sangat kuat (Allen & Syahfitra, 2024).

Perbedaan respons spektral ini adalah kunci untuk menciptakan indeks vegetasi. Indeks vegetasi adalah nilai numerik yang didapatkan melalui transformasi matematis dari nilai-nilai spektral ini, yang berfungsi sebagai proksi kuantitatif untuk biomassa tanaman, kesehatan, dan kapasitas fotosintetik.

Analisis Indeks Vegetasi Utama

Beberapa indeks vegetasi telah dikembangkan untuk mengukur kesehatan tanaman. diantara yang paling umum digunakan untuk pemantauan tanaman padi adalah:

Normalized Difference Vegetation Index (NDVI)

NDVI adalah salah satu indeks yang paling populer dan sering digunakan karena algoritmanya yang sederhana dan efektivitasnya yang terbukti dalam berbagai penelitian (Ariani, 2019). *NDVI* mengukur perbedaan antara pantulan inframerah dekat (NIR) dan pantulan merah (*Red*) yang dinormalisasi, dengan rumus sebagai berikut:

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Nilai *NDVI* berkisar dari -1 hingga +1. Nilai yang mendekati +1 mengindikasikan vegetasi yang sangat sehat dan padat, karena pantulan NIR yang tinggi dan pantulan Red yang rendah. Sebaliknya, nilai yang mendekati 0 mengindikasikan area gundul atau bebatuan, sementara nilai negatif menunjukkan air atau salju. Dalam konteks pertanian, menurut nilai *NDVI* akan meningkat seiring dengan klorofil yang kuat untuk memantau tahapan pertumbuhan padi dari tanam hingga masa generatif.

Enhanced Vegetation Index (EVI)

Enhanced Vegetation Index (EVI) merupakan indeks yang serupa dengan *NDVI* tetapi dirancang untuk mengatasi beberapa keterbatasan *NDVI*. *EVI* mengoreksi gangguan atmosfer dan kebisingan latar belakang kanopi tanaman, sehingga menjadikannya lebih sensitif di area dengan vegetasi yang sangat padat. *EVI* mencapai perbaikan ini dengan memasukkan band biru (B) dan koefisien koreksi ke dalam rumusnya, memungkinkan perhitungan rasio antara nilai NIR dan Red sambil mengurangi noise latar belakang dan kejenuhan di sebagian besar kasus.

$$EVI = G * \frac{NIR - R}{NIR - C1 * R - C2 * B + L}$$

Rumus ini menunjukkan kompleksitas *EVI* yang lebih tinggi namun memberikan akurasi yang lebih baik dalam kondisi tertentu.

Indeks Lainnya

Studi kasus juga menguji indeks lain seperti *Soil-Adjusted Vegetation Index (SAVI)* dan *Atmospherically Resistant Vegetation Index (ARVI)*. *SAVI* dirancang untuk meminimalkan pengaruh pantulan dari tanah yang terbuka, sedangkan *ARVI* dirancang khusus untuk memperhitungkan gangguan atmosfer dengan menambahkan panjang gelombang biru dalam perhitungannya.

Pemilihan indeks vegetasi merupakan keputusan metodologis yang krusial. Meskipun rumusnya tampak sederhana, setiap indeks dirancang untuk kondisi lingkungan yang berbeda. Misalnya, *NDVI* rentan terhadap kejenuhan pada vegetasi yang sangat lebat dan fluktuasi atmosfer. Penggunaan indeks yang tidak sesuai dapat menyebabkan estimasi yang tidak akurat. Oleh karena itu, keragaman indeks yang digunakan dalam penelitian, seperti *NDVI*, *SAVI*, dan *ARVI*, mencerminkan upaya untuk menemukan pendekatan yang paling sesuai dengan kondisi lapangan yang kompleks, yang pada akhirnya memengaruhi hasil estimasi produksi secara substansial.

Klasifikasi Tutupan Lahan

Klasifikasi yang digunakan menggunakan metode *supervised classification* dengan mengambil *training sample* untuk tiap kelasnya. Algoritma klasifikasi yang digunakan adalah algoritma *Random Forest (RF)* dan *Classification and Regression Trees (CART)*. RF adalah algoritma yang bekerja dengan membangun pohon keputusan dimana kelas sampel akan diprediksi untuk pengujian (Azhar & Pardede, 2021).

Uji Akurasi

Hasil olahan citra dianalisis untuk selanjutnya dilakukan penilaian akurasi (*Accuracy assessment*). Akurasi merupakan perbandingan antara data hasil klasifikasi dengan kondisi lapangan. Pengguna harus melakukan pengecekan dan pengambilan beberapa sampel di lapangan sebagai pembandingan. Tingkat nilai akurasi citra menjelaskan apakah hasil interpretasi baik digunakan atau tidak untuk analisis selanjutnya (Fitriawan, 2020)

HASIL DAN PEMBAHASAN

Analisis Studi Kasus: Estimasi Produksi Padi di Kabupaten Sleman

Untuk menguji kelayakan metodologi estimasi produksi padi berbasis penginderaan jauh, sebuah penelitian telah dilakukan di Kabupaten Sleman. Kerangka kerja penelitian ini melibatkan pembangunan model regresi yang mengaitkan nilai indeks vegetasi dari citra satelit Landsat 8 OLI dengan data produktivitas padi yang dikumpulkan dari 45 sampel lapangan.

Proses analisis regresi menghasilkan tiga rumus regresi yang berbeda, masing-masing untuk setiap indeks vegetasi yang diuji. Rumus ini dirancang untuk memprediksi produktivitas padi (Y) berdasarkan nilai indeks vegetasi yang bersangkutan:

$$A. NDVI : Y = (-4,45 * NDVI) + 7,9$$

$$B. SAVI : Y = (-7,09 * SAVI) + 7,94$$

$$C. ARVI ; Y = (3,77 * ARVI) + 5,98$$

Tabel 1 meringkas model regresi dan hasil estimasi produksi dari studi kasus tersebut, memberikan gambaran yang jelas tentang perbedaan hasil yang dihasilkan oleh setiap indeks.

Tabel 1. Ringkasan Model Regresi dan Estimasi Produksi Padi

Indeks Vegetasi	Rumus Regresi	Estimasi Produksi (Ton)
NDVI	$Y = (-4,45 * NDVI) + 7,9$	345.373
SAVI	$Y = (-7,09 * SAVI) + 7,94$	350.685
ARVI	$(3,77 * ARVI) + 5,98$	250.957

Perbedaan yang signifikan dalam estimasi produksi total antara indeks-indeks yang berbeda, terutama antara *SAVI* dan *ARVI*, menurut (Sarono & B.S, 2016) menyoroti kompleksitas dalam pemodelan hasil panen. Ini memicu pertanyaan kritis tentang indeks mana yang paling dapat diandalkan, sebuah pertanyaan yang dijawab lebih lanjut melalui proses validasi model.

Validasi Model dan Analisis Kritis Keterbatasan Metodologis

Untuk memastikan keandalan model yang telah dibangun, sebuah proses validasi dilakukan menggunakan 23 sampel data lapangan yang berbeda dari 45 sampel yang digunakan untuk pembangunan model. Uji akurasi ini bertujuan untuk mengevaluasi seberapa baik setiap model mampu memprediksi produktivitas padi di lokasi yang belum pernah "dilihat" oleh model sebelumnya. Hasil uji akurasi menunjukkan tingkat keberhasilan sebagai berikut:

$$A. \text{ Akurasi model produktivitas } NDVI: 77,30\%.$$

B. Akurasi model produktivitas *SAVI*: 76,49%.

C. Akurasi model produktivitas *ARVI*: 73,01%

Tingkat akurasi di atas 70% secara umum dianggap memuaskan untuk model prediktif (Mulyaqin *et al.*, 2022). Namun, analisis lebih dalam mengungkapkan keterbatasan yang mendasar.

Penelitian tersebut secara eksplisit menyatakan bahwa koefisien determinasi (R^2) dari model-model regresi ini sangat rendah. Koefisien R^2 mengukur seberapa baik model dapat menjelaskan variasi dalam variabel dependen (produktivitas padi) berdasarkan variabel independen (indeks vegetasi). Nilai R^2 yang dihasilkan adalah:

A. *NDVI*: 0,033

B. *SAVI*: 0,042

C. *ARVI*: 0,028

Tabel 2 menyajikan perbandingan antara akurasi model dan koefisien determinasi (R^2), menyoroti perbedaan antara kedua metrik tersebut. Hasil validasi model dan koefisien determinasi (R^2) ditampilkan pada Tabel 2.

Tabel 2. Hasil validasi model dan koefisien determinasi (R^2)

Indeks Vegetasi	Persentase Akurasi	Koefisien Determinasi (R^2)
NDVI	77,30%	0,033
SAVI	76,49%	0,042
ARVI	73,01%	0,028

Meskipun akurasi model tampak cukup baik, berdasarkan Z Damayanti (2025) nilai R^2 yang sangat rendah ini mengindikasikan bahwa model regresi linier sederhana yang digunakan hanya mampu menjelaskan kurang dari 5% dari total variasi produktivitas padi di lapangan. Hal ini memiliki implikasi kritis. Tingkat akurasi yang "memuaskan" mungkin disebabkan oleh faktor-faktor lain yang tidak terkait dengan kemampuan prediktif model itu sendiri, atau oleh karakteristik khusus dari sampel data (Syahfitra *et al.*, 2021).

Keterbatasan ini diperkuat oleh penjelasan bahwa data produktivitas lapangan yang digunakan memiliki variabilitas yang besar dan distribusi yang tidak normal. Hal ini menunjukkan bahwa produktivitas padi tidak hanya dipengaruhi oleh kondisi vegetasi yang ditangkap oleh citra satelit, tetapi juga oleh berbagai faktor lain seperti curah hujan, struktur tanah, pH, dan ketersediaan air dan udara dalam tanah. Model regresi sederhana yang hanya mengandalkan satu variabel (indeks vegetasi) tidak memadai untuk menangkap kompleksitas interaksi antara faktor-faktor ini. Oleh karena itu, keberhasilan estimasi yang akurat di masa depan akan memerlukan model yang lebih canggih, yang mampu mengintegrasikan data multispektral dengan data multidisiplin lainnya untuk memberikan gambaran yang lebih holistik dan akurat.

Perbandingan Komprehensif: Penginderaan Jauh vs Metode Konvensional

Pendekatan estimasi produksi padi menggunakan penginderaan jauh, khususnya dengan platform seperti GEE, menawarkan keunggulan signifikan dibandingkan metode konvensional (Ardiansyah *et al.*, 2024). Kelebihan utama dari pendekatan ini adalah efisiensi waktu dan tenaga kerja. Sementara metode konvensional membutuhkan survei lapangan yang intensif, mahal, dan memakan waktu, penginderaan jauh memungkinkan analisis area yang luas dalam waktu yang relatif singkat. Kemampuan GEE untuk memproses data petabyte secara paralel mengubah logistik pemantauan dari skala lokal menjadi skala regional atau bahkan nasional, sebuah tugas yang tidak mungkin dilakukan dengan survei manual.

Selain itu, teknologi penginderaan jauh memungkinkan pemantauan yang berkelanjutan. Metode konvensional sering kali hanya dapat memberikan estimasi pada satu titik waktu, yaitu pada saat panen. Sebaliknya, penginderaan jauh dapat memantau fenologi tanaman padi—yaitu, tahapan pertumbuhan dari tanam hingga panen sepanjang musim tanam. Data ini sangat berharga untuk mendeteksi anomali pertumbuhan, mengidentifikasi area yang membutuhkan intervensi, dan memprediksi hasil panen jauh sebelum masa panen tiba. Hal ini mendukung pengambilan keputusan yang proaktif, yang sangat penting untuk menghadapi tantangan seperti ancaman kekeringan atau hama.

Meskipun penginderaan jauh menawarkan keunggulan yang jelas, penting untuk diakui bahwa kedua metode ini tidak saling menggantikan, melainkan saling melengkapi. Data lapangan yang dikumpulkan melalui metode konvensional tetap krusial sebagai "kebenaran di lapangan" (*ground truth*). Data ini sangat penting untuk kalibrasi dan validasi model penginderaan jauh. Sebagaimana yang ditunjukkan oleh koefisien R^2 yang rendah dalam studi kasus Sleman, model yang hanya mengandalkan data satelit memiliki keterbatasan. Oleh karena itu, pendekatan yang paling efektif adalah model hibrida, di mana penginderaan jauh digunakan untuk mengidentifikasi tren dan anomali pada skala besar, sementara data lapangan yang terbatas digunakan untuk mengkalibrasi model dan memastikan akurasi di tingkat lokal.

KESIMPULAN DAN SARAN

Platform *Google Earth Engine (GEE)* terbukti mampu mempercepat perolehan citra satelit dan pemrosesan data skala besar melalui teknologi *Cloud Computing* dibandingkan metode konvensional. Meskipun model indeks vegetasi seperti NDVI, SAVI, dan ARVI memiliki tingkat akurasi di atas 70% namun nilai koefisien determinasi (R^2) yang dihasilkan sangat rendah, yakni di bawah 0,05. Hasil tersebut menunjukkan bahwa model regresi linier sederhana yang hanya mengandalkan indeks vegetasi tidak cukup kuat untuk menjelaskan variabilitas produktivitas padi di lapangan. Produktivitas padi secara nyata lebih dipengaruhi oleh faktor eksternal yang kompleks, seperti curah hujan, struktur tanah, pH, serta ketersediaan air dan udara dalam tanah. Secara keseluruhan, GEE merupakan alat monitoring yang potensial, namun efektivitasnya dalam mengestimasi produksi sangat bergantung pada pengembangan model yang lebih baik.

Penelitian selanjutnya sebaiknya mengintegrasikan data multidisiplin ke dalam platform GEE, termasuk data iklim (curah hujan) dan data hidrologi, untuk meningkatkan akurasi prediksi. Penggunaan algoritma yang lebih maju seperti *Machine Learning* atau *Deep Learning* sangat disarankan guna mengidentifikasi pola hubungan non-linier yang tidak tertangkap oleh regresi sederhana.

DAFTAR PUSTAKA

- Allen, R. V., & Syahfitra, M. (2024). Pendugaan Kerapatan Vegetasi Menggunakan Metode NDVI di Kota Payakumbuh. *Atech-i*, 2(1), 32–40.
- Ardiansyah, M., Munibah, K., & Raniah, N. (2024). Estimasi Umur Padi pada Citra Sentinel-2 dengan Pendekatan Gaussian Mixture Model. *Jurnal Ilmu Tanah Dan Lingkungan*, 26(1), 21–28. <https://doi.org/10.29244/jitl.26.1.21-28>
- Ariani, D., Prasetyo, Y., & Sasmito, B. (2019). Estimasi tingkat produktivitas padi berdasarkan algoritma NDVI, EVI dan SAVI menggunakan citra Sentinel-2 multitemporal (Studi kasus: Kabupaten Pekalongan, Jawa Tengah). *Jurnal Geodesi Undip*, 9(1), 207-216.

- Badan Pusat Statistik RI. (2018). *Upaya Perbaikan Data Padi Dengan Metode Kerangka Sampel Area (KSA)*. BPS Indonesia.
- Gandharum, L., Mulyani, M. E., Hartono, D. M., Karsidi, A., & Ahmad, M. (2021). Remote sensing versus the area sampling frame method in paddy rice acreage estimation in Indramayu regency, West Java Province, Indonesia. *International Journal of Remote Sensing*, 42(5), 1738–1767. <https://doi.org/10.1080/01431161.2020.1842541>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.05.010>
- Indarto. (2014). *Penginderaan Jauh: Metode Analisis Citra Satelit*. Andi Offset.
- Kementrian Pertanian Republik Indonesia. (2022). *STATISTIK PERTANIAN*.
- Mooy, H., Watuwaya, B. K., Negeri Kupang, S., Timor Raya Km, J., & Kupang, K. (2023). *Peran Penginderaan Jauh dan Sistem Informasi Geografis dalam Penerapan Pertanian Cerdas di Era Industri 4.0 The Role of Remote Sensing and Geographic Information System in Smart Farming Industry 4.0*. <https://jurnal.polbangtanyoma.ac.id/pros2023yoma/15>
- Mueller, N. D., Gerber, J. S., Johnston, M., Ray, D. K., Ramankutty, N., & Foley, J. A. (2012). Closing yield gaps through nutrient and water management. *Nature*, 490(7419), 254-257. <https://doi.org/10.1038/nature11420>
- Mulyaqin, T., Kardiyono, K., 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. *Jurnal Ilmu Pertanian Indonesia*, 27(2), 226–236. <https://doi.org/10.18343/jipi.27.2.226>
- Sarono, & B.S, S. H. M. (2016). Estimasi Produksi Padi dengan Menggunakan NDVI (Normalized Difference Vegetation Index) pada Lahan Sawah Hasil Segmentasi Citra ALOS di Kabupaten Karanganyar. *Bumi Indonesia*, 5(2), 1–7. <http://lib.geo.ugm.ac.id/ojs/index.php/jbi/article/view/705>
- Syahfitra, M., Wardhani, N. W. S., & Iriany, A. (2021). Modeling Cabbage Production in Malang East Java with GSTAR Approach. *Proceedings of the 1st International Conference on Mathematics and Mathematics Education (ICMMEd 2020)*, 550(Icmmed 2020), 299–303. <https://doi.org/10.2991/assehr.k.210508.078>
- Thorp, K. R., & Drajat, D. (2021). Deep machine learning with Sentinel satellite data to map paddy rice production stages across West Java, Indonesia. *Remote Sensing of Environment*, 265, 112679. <https://doi.org/10.1016/j.rse.2021.112679>
- Van Dijk, M., Morley, T., Rau, M. L., & Saghai, Y. (2021). A meta-analysis of projected global food demand and population at risk of hunger for the period 2010–2050. *Nature Food*, 2(7), 494-501. <https://doi.org/10.1038/s43016-021-00322-9>
- 'Z Damayanti, D. R. (2025). *Pemodelan Produktivitas Padi Menggunakan Teknologi Penginderaan Jauh Di Kecamatan Gading Rejo, Kabupaten Pringsewu*. Universitas Lampung.