Jurnal Fisika Unand (JFU)
Vol. 15, No. 1, Januari 2026, hal. 70 – 78
ISSN: 2302-8491 (Print); 2686-2433 (Online)
https://doi.org/10.25077/jfu.15.1.70-78.2026

Open Access

Klasifikasi Tanaman menggunakan Metode *Deep Learning Residual Network* (ResNet) Berbasis *Data Time Series* Penginderaan Jauh di Desa Girimulyo, Lampung Timur

Muhammad Ario Eko Rahadianto[1], Putri Wahyu Sejati[1], Adam Irwansyah Fauzi[1,2*], Aulia Try Atmojo[1], Tika Widayanti[1], Rizky Ahmad Yudanegara[1]
[1]Teknik Geomatika, Institut Teknologi Sumatera, Indonesia
[2]The University of Natural Resources and Life Sciences, Vienna (BOKU), Austria

Info Artikel

Histori Artikel:
Diajukan: 13 Oktober 2025
Direvisi: 20 Desember 2025
Diterima: 30 Januari 2026

Kata kunci:
Klasifikasi Jenis Tanaman
Penginderaan Jauh
Residual Network (ResNet)
Time Series
Sentinel-2A

Penulis Korespondensi:
Adam Irwansyah Fauzi
Email: adam.fauzi@gt.itera.ac.id

ABSTRAK

Sebagian besar penduduk Indonesia bekerja di sektor pertanian, sehingga peta jenis tanaman penting untuk mendukung ketahanan pangan. Penelitian ini mengevaluasi klasifikasi time series berbasis Residual Network (ResNet) untuk pemetaan tanaman. Data yang digunakan berupa citra Sentinel-2A periode Mei 2021–Mei 2022 dengan 120 sampel pada lima kelas: Jagung, Kelapa, Non-tanaman, Pisang, dan Tanaman Lain. Data diolah menjadi *Earth Observation (EO) data cube* terregulerisasi, kemudian dilatih menggunakan sampel melalui dua skema *Self-Organizing Map* (SOM), yaitu *single clustering* (SC) dan *double clustering* (DC). Model ResNet dilatih dengan data tersaring dan diuji dengan variasi epoch. Hasil penelitian menghasilkan peta jenis tanaman wilayah Girimulyo, Lampung Timur, yang dismoothing menggunakan metode Bayesian. Uji akurasi menunjukkan skema SC pada epoch ke-100 mencapai 87%, melampaui ambang minimum 85%. Sebaliknya, skema DC memberi hasil lebih rendah akibat berkurangnya data pelatihan. Dengan demikian, klasifikasi time series berbasis ResNet efektif untuk pemetaan jenis tanaman di daerah penelitian.

Keywords:
Crop Type Classification
Remote Sensing
Residual Network (ResNet)
Time Series
Sentinel-2A

Most Indonesians work in agriculture, making crop-type maps essential for food security. This study evaluates time-series classification using Residual Network (ResNet) for crop mapping. Sentinel-2A imagery from May 2021 to May 2022 was used with 120 samples across five classes: Corn, Coconut, Non-crop, Banana, and Other Crops. The data were processed into a regularized Earth Observation (EO) data cube and trained using samples filtered with Self-Organizing Map (SOM) under two schemes: single clustering (SC) and double clustering (DC). The ResNet model was trained with filtered data and tested with varying epochs. The study produced a crop-type map of Girimulyo, East Lampung, smoothed with the Bayesian method. Accuracy assessment showed that SC at 100 epochs achieved 87%, exceeding the 85% threshold, while DC yielded lower accuracy due to reduced training data. These results confirm that ResNet-based time-series classification is effective for crop-type mapping in the study area.

Copyright © 2026 Author(s).

I. PENDAHULUAN

Sektor pertanian Indonesia memiliki peran krusial bagi perekonomian nasional dan ketahanan pangan. Sektor pertanian menyumbang sekitar 32% dari total tenaga kerja di Indonesia dan menempati urutan ketiga dalam kontribusinya terhadap PDB (Pratiwik & Rahmayani, 2023). Di wilayah pedesaan, pertanian menjadi sumber utama pangan dan pendapatan, serta menopang ketahanan pangan rumah tangga selama krisis seperti pandemi COVID-19 (Pratiwik & Rahmayani, 2023; Venna & Romulo, 2024).

Perubahan iklim menyebabkan cuaca ekstrem seperti kekeringan dan banjir sehingga menurunkan produktivitas tanaman (Kurnianto, 2024; Suranny et al., 2022). Alih fungsi lahan untuk industri dan pemukiman turut mengurangi luas sawah dari 8,4 juta hektare pada 1990 menjadi 7,18 juta hektare pada 2022 (Ivanka et al., 2024). Selain itu, pertumbuhan penduduk meningkatkan kebutuhan pangan di tengah keterbatasan sumber daya lahan dan air (Karimidastenaei et al., 2022). Kondisi ini menuntut inovasi dan teknologi adaptif agar sektor pertanian tetap berdaya saing dalam menghadapi perubahan lingkungan dan ekonomi global.

Selain pemenuhan kebutuhan pangan, pertanian juga berperan dalam pengentasan kemiskinan (Maulu et al., 2021), kekurangan gizi (Singh, 2022), dan pelestarian lingkungan (Çakmakçı et al., 2023). Namun, tantangan seperti perubahan pola tanam akibat fluktuasi harga dan kebijakan (Sun et al., 2021), degradasi lahan (Setiawan et al., 2023), serta ketidakpastian iklim yang memengaruhi produktivitas pertanian (Risal et al., 2022). Oleh sebab itu, diperlukan teknologi pemantauan lahan yang efisien, akurat, dan adaptif.

Teknologi penginderaan jauh berbasis citra satelit menjadi solusi potensial karena mampu menyediakan data spasial luas dan konsisten. Teknologi ini telah digunakan untuk pemetaan tutupan lahan (Dharmawan et al., 2021), deteksi kerusakan lingkungan (Fauzi et al., 2023), deforestasi (Chaddad et al., 2022), dan perubahan bentuk bumi (Anggara et al., 2023). Dalam konteks pertanian, penginderaan jauh digunakan untuk klasifikasi jenis tanaman dan analisis perubahan penggunaan lahan (Omia et al., 2023; B. Wu et al., 2023; Zhang et al., 2021;Zhang et al., 2024).

Penelitian ini menggunakan citra Sentinel-2 yang memiliki resolusi tinggi (10 m), revisit time 5 hari, serta kanal spektral seperti *Near-Infrared* (NIR) dan *Short-Wave Infrared* (SWIR) untuk analisis vegetasi (Singh et al., 2022). Dengan dukungan Deep Learning, khususnya *Residual Network* (ResNet), analisis citra menjadi lebih akurat melalui ekstraksi fitur spasial-temporal yang kompleks (Maxwell et al., 2021); W. Wu et al., 2025; Zhao et al., 2022; Zhuo & Zhou, 2021). ResNet terbukti efektif meningkatkan akurasi klasifikasi tanaman berbasis citra satelit (Omia et al., 2023; Wu et al., 2023; Zhang et al., 2024).

Penelitian ini mengkaji penerapan ResNet untuk pemetaan pertanian berbasis *time-series* guna mendukung ketahanan pangan di Desa Giri Mulyo, Kecamatan Marga Sekampung, Kabupaten Lampung Timur, yang memiliki beragam komoditas pertanian termasuk alpukat unggulan "Siger" (Ilyas et al., 2024a). ResNet memiliki keunggulan dibandingkan CNN konvensional karena penggunaan residual connections yang mampu mengatasi masalah vanishing gradient, sehingga memungkinkan pelatihan jaringan yang lebih dalam dan meningkatkan akurasi klasifikasi citra tanaman (He et al., 2016). Dengan pemanfaatan teknologi *Deep Learning*, penelitian ini diharapkan dapat menghasilkan model klasifikasi tanaman yang lebih akurat dan efisien dalam memantau perubahan kondisi pertanian.

II. METODE

2.1 Lokasi Penelitian

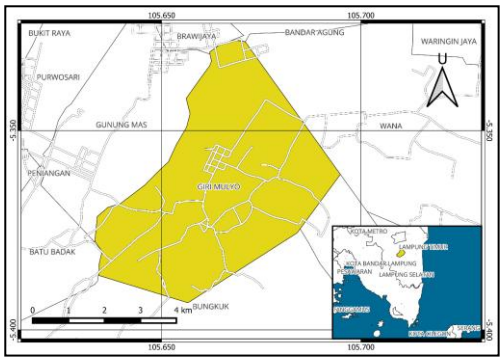

Gambar 1 Lokasi penelitian

Penelitian ini berfokus pada daerah Desa Giri Mulyo, Kecamatan Marga Sekampung, Kabupaten Lampung Timur, Provinsi Lampung dan sekitar wilayah tersebut (Gambar 1). Secara geografis, Desa Giri Mulyo terletak pada koordinat 5°21’31” LS dan 105°39’30” BT dengan sebagian besar wilayahnya merupakan kawasan pertanian non-sawah. Desa Giri Mulyo adalah desa terluas di kecamatannya, dengan lahan pertanian yang didominasi oleh tanaman jagung (BPS, 2021). Selain jagung, tanaman lain yang terdapat di desa ini meliputi kelapa, padi, pisang, lada, coklat, alpukat, dan lain-lain (Ilyas et al., 2024).

2.2 Data

Data yang digunakan dalam penelitian ini terdiri dari tiga jenis utama, sebagaimana dirangkum dalam Tabel 1. Penelitian ini memanfaatkan citra satelit Sentinel-2A, hasil kerja sama *European Commission* dan *European Space Agency* melalui program *Global Monitoring for Environment and Security* (GMES). Data citra dengan interval 5 Mei 2021 hingga 5 Mei 2022 mencakup kanal B03 (Green), B04 (Red), B08 (NIR), B8A (Narrow NIR), B11 (SWIR), serta SCL (*Scene Classification Layer*), yang diakses melalui platform *Amazon Web Services* (AWS). Data pendukung meliputi batas administrasi Desa Girimulyo dari Badan Informasi Geospasial (BIG) serta 150 titik sampel koordinat tanaman dengan lima kelas utama: jagung, kelapa, pisang, non-tanaman, dan tanaman lainnya.

Tabel 1 Data Penelitian

Nama Data	Tipe Data	Resolusi/Skala	Waktu	Sumber
Citra Satelit Sentinel-2	Raster	10 m		*European Space Agency*
Batas Administrasi Desa Girimulyo	Vektor (Poligon)	1:25.000		Badan Informasi Geospasial
Data Sampel Lapangan	Vektor (Titik)	-		Survei Lapangan

Sebaran titik sampel yang digunakan dalam penelitian ini terbagi ke dalam lima kelas utama, yaitu jagung, kelapa, pisang, non-tanaman, dan tanaman lainnya. Dari total 150 titik sampel, data tersebut dibagi menjadi dua subset, yakni 80% untuk proses *training* model dan 20% untuk proses validasi guna mengukur kinerja klasifikasi. Seluruh titik sampel diperoleh melalui survei lapangan yang dilakukan pada tahun 2022 dengan metode pencatatan koordinat menggunakan perangkat GPS serta verifikasi jenis tanaman secara langsung di lokasi penelitian. Pembagian data *training* dan *validasi* dilakukan secara acak namun tetap mempertahankan proporsi setiap kelas (*stratified random sampling*) agar representasi jenis tanaman pada kedua subset tetap seimbang.

2.3 Prosedur

Penelitian ini menggunakan pendekatan *Deep Learning* dengan arsitektur *Residual Network* (ResNet) untuk klasifikasi citra satelit berbasis time series. Dua skema klasifikasi diuji, yaitu *Single Clustering* dan *Double Clustering*, masing-masing dengan parameter epoch 100, 150, 200, 250, dan 300, guna mengevaluasi pengaruh jumlah epoch terhadap akurasi model. Data utama berupa citra Sentinel-2 periode 5 Mei 2021–5 Mei 2022 dengan kanal B03, B04, B08, B8A, B11, dan SCL, diunduh dari

Amazon Web Services (AWS). Data tambahan meliputi batas administrasi Desa Girimulyo dari BIG, serta 150 titik sampel lapangan yang terbagi menjadi lima kelas (jagung, kelapa, pisang, non-tanaman, dan tanaman lainnya). Meskipun jumlah sampel lapangan relatif terbatas, beberapa studi menunjukkan bahwa arsitektur ResNet tetap mampu memberikan performa yang baik pada ukuran data yang moderat karena adanya *residual connections* yang mempermudah proses optimisasi, terutama ketika dikombinasikan dengan pembagian data yang seimbang dan strategi pelatihan yang tepat (He et al., 2016; Shorten & Khoshgoftaar, 2019). Dataset dibagi menjadi 80% untuk training dan 20% untuk validasi dengan metode *stratified random sampling* guna menjaga proporsi tiap kelas.

Pengolahan data dilakukan dalam beberapa tahap, meliputi: (1) pembuatan *Earth Observation (EO) Data Cube* untuk menyusun data time series dalam bentuk array tiga dimensi, (2) *regularization* untuk menyeragamkan resolusi spasial dan temporal, (3) klasterisasi dengan metode Self-Organizing Map (SOM) untuk mengontrol kualitas data sampel, dan (4) filtering untuk mengoreksi gangguan atmosfer, kesalahan geolokasi, serta nilai yang hilang. Data yang telah diproses kemudian digunakan untuk training model ResNet, diikuti oleh *Bayesian post-processing* berupa *probability smoothing* pada domain temporal, di mana probabilitas kelas hasil klasifikasi disesuaikan berdasarkan distribusi posterior guna mengurangi fluktuasi klasifikasi antar waktu akibat noise dan variabilitas data citra (Pelletier et al., 2019). Evaluasi model dilakukan dengan membandingkan hasil klasifikasi terhadap data sampel lapangan yang telah divalidasi, menggunakan metrik *Overall Accuracy* (OA), *User Accuracy* (UA), *Producer Accuracy* (PA), dan *Kappa Coefficient* (KA). Tahapan ini memastikan bahwa model menghasilkan peta klasifikasi dengan probabilitas kelas yang akurat dan dapat diandalkan untuk analisis spasial pada wilayah studi.

III. HASIL DAN DISKUSI

3.1 Hasil *Model Training ResNet*

Penelitian ini mengimplementasikan metode klasifikasi citra penginderaan jauh berbasis *time series* dengan menggunakan arsitektur *Residual Network (ResNet)*. ResNet dipilih karena kemampuannya mengatasi masalah *vanishing gradient* yang umum terjadi pada jaringan saraf tiruan dengan kedalaman berlapis. Pada jaringan konvensional, penambahan lapisan justru sering menurunkan akurasi akibat error yang terakumulasi, sedangkan ResNet dirancang untuk meminimalkan error dengan memanfaatkan konsep *skip connection* atau *residual learning*, sehingga mampu mempertahankan bahkan meningkatkan akurasi pada jaringan yang lebih dalam. Pendekatan ini dinilai sangat efektif dalam analisis *time series* karena mampu menangkap pola temporal secara lebih baik dibandingkan metode klasifikasi tradisional.

Untuk memperoleh performa optimal, dilakukan serangkaian eksperimen dengan mengatur variasi jumlah *epoch* pada tahap *training*. Lima skenario *epoch* digunakan, yaitu 100, 150, 200, 250, dan 300, untuk mengevaluasi pengaruh jumlah iterasi terhadap peningkatan akurasi. Berdasarkan hasil uji *training*, pada skema satu kali klasterisasi (*single clustering*), akurasi tertinggi dicapai pada *epoch* 100, dengan nilai akurasi mendekati 0,9 (>0,85). Setelahnya, akurasi diikuti secara berurutan oleh *epoch* 300, 250, dan 150. Sementara itu, pada skema dua kali klasterisasi (*double clustering*), akurasi tertinggi dicapai pada *epoch* 250 dengan nilai lebih dari 0,9, disusul oleh *epoch* 200, 100, 150, dan 300. Hasil ini menunjukkan bahwa performa ResNet tidak hanya dipengaruhi oleh kedalaman jaringan tetapi juga oleh pemilihan jumlah *epoch* yang tepat. Secara umum, *double clustering* memberikan hasil yang lebih konsisten dalam mencapai akurasi tinggi dibandingkan *single clustering*.

3.2 Hasil Klasifiasi Peta Jenis Tanaman

Hasil utama dari penelitian ini adalah peta jenis tanaman yang memetakan distribusi vegetasi di wilayah studi secara detail. Peta ini dihasilkan melalui serangkaian eksperimen klasifikasi dengan berbagai skema dan variasi *epoch*. Hasil peta terbaik pada *single clustering* dengan *epoch* 100 disajikan pada Gambar 2 (a). Gambar 2 (a) menunjukkan peta jenis tanaman hasil klasifikasi dengan akurasi tertinggi pada skema *Single Clustering* (SC) menggunakan *epoch* 100. Sementara itu, Gambar 2 (b) menampilkan peta jenis tanaman dari hasil klasifikasi dengan skema *double clustering* (DC), yang hasil terbaiknya terdapat pada *epoch* 250.

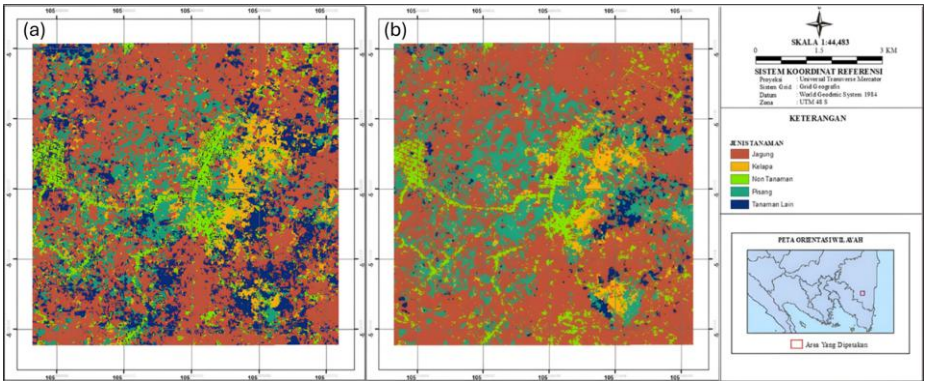

Gambar 2 Peta Klasifikasi Jenis Tanaman skema (a) *Single Clustering* dengan *Epoch* 100 (b) *Double Clustering* dengan *Epoch* 250

Setelah seluruh proses klasifikasi selesai, terlihat bahwa distribusi warna pada peta bervariasi, yang menunjukkan adanya perbedaan luas wilayah untuk setiap kelas tanaman di antara *epoch* dan skema yang diuji. Perbandingan informasi luas wilayah antar kelas ditampilkan pada Tabel 2.

Tabel 2 Luas Kelas Jenis Tanaman setiap skema *clustering* dan *epoch*

Epoch	Luas Kelas (km^2)									
	Single Clustering					*Double Clustering*				
	Jagung	Kelapa	Non-Tanaman	Pisang	Tanaman Lain	Jagung	Kelapa	Non-Tanaman	Pisang	Tanaman Lain
100	21,6366	3,7778	3,4137	7,0895	9,0394	26,3957	5,8546	4,2378	3,4181	5,0508
150	24,1719	5,1228	4,1563	5,8871	5,6189	26,3957	5,8546	4,2380	3,4181	5,0508
200	20,4836	3,7966	4,23475	7,7888	8,5405	24,3935	2,6342	3,3733	11,6258	2,9302
250	19,1017	7,8810	5,2350	4,8877	7,8516	29,0350	1,8105	3,4021	9,2280	1,4814
300	27,7642	4,2331	2,8899	4,7267	5,3431	30,7868	5,7692	3,3952	4,0106	0,9952

Tabel 2 merangkum luas wilayah tiap kelas tanaman pada skema SC dan DC. Secara umum pada skema SC, pada semua variasi *epoch* (100 hingga 300), kelas jagung mendominasi luasan wilayah. Luas terkecil pada *epoch* 100, 150, dan 300 berada pada kelas non-tanaman, sedangkan pada *epoch* 200 luas terkecil terdapat pada kelas kelapa, dan pada *epoch* 250 pada kelas pisang. Sementara pada skema DC, kelas jagung tetap menjadi dominan pada seluruh *epoch*. Namun, terdapat variasi pada kelas dengan luas terkecil, di mana kelas pisang memiliki luas terkecil pada *epoch* 100 dan 150, kelas kelapa pada *epoch* 200, serta kelas tanaman lain pada *epoch* 250 dan 300. Perbedaan hasil luasan wilayah antara peta SC dan DC disebabkan oleh perbedaan jumlah klaster yang digunakan pada proses *clustering*, serta pengaruh jumlah *epoch* yang berbeda dalam proses pelatihan model. Hal ini menunjukkan bahwa kombinasi parameter *epoch* dan strategi *clustering* sangat memengaruhi hasil klasifikasi spasial dan luasan dari tiap kelas tanaman.

Dominasi kelas jagung pada hasil klasifikasi, baik pada skema SC maupun DC, konsisten dengan data lapangan dan laporan Badan Pusat Statistik (BPS, 2021) yang menyatakan bahwa lahan pertanian di Desa Girimulyo memang didominasi oleh tanaman jagung. Hal ini menunjukkan bahwa model ResNet mampu mengenali pola spektral jagung dengan baik pada data *time series* Sentinel-2, terutama pada kanal spektral yang sensitif terhadap vegetasi seperti NIR (B08) dan SWIR (B11). Sementara itu, perbedaan luasan pada kelas dengan area kecil, seperti kelapa atau pisang, kemungkinan besar dipengaruhi oleh keterbatasan jumlah sampel pelatihan serta variasi fenologi tanaman yang lebih kompleks dibandingkan jagung. Strategi *double clustering* (DC) terlihat memberikan distribusi spasial yang lebih konsisten dan akurasi yang lebih tinggi dibandingkan *single clustering* (SC). Hal ini dapat dijelaskan karena DC mampu meminimalkan pencampuran kelas (*class mixing*) dengan mengelompokkan data sampel secara lebih selektif sebelum proses *training*. Selain itu, peningkatan akurasi pada DC dengan *epoch* tertentu (misalnya *epoch* 250) menunjukkan bahwa model tidak mengalami *overfitting*, karena proses klasterisasi tambahan membantu model untuk mengenali pola dominan tanpa kehilangan informasi minor dari kelas lain.

3.3 Uji Akurasi

Akurasi time series pada penelitian ini secara otomatis ditentukan oleh dataset yang telah dimodelkan. Fungsi perhitungan akurasi bekerja dengan membuat data validasi secara otomatis,

kemudian menghitung *confusion matrix* dari data tersebut. Nilai akurasi ditampilkan dalam Tabel 3. yang memuat dua parameter utama, yaitu *Overall Accuracy* (OA) dan *Kappa Accuracy* (KA). Akurasi time series dapat dihitung langsung dari dataset yang dimodelkan maupun dari citra hasil klasifikasi. Pada perhitungan berbasis dataset time series, validasi dilakukan secara otomatis oleh fungsi pemodelan, sedangkan pada perhitungan akurasi citra hasil klasifikasi diperlukan data validasi lapangan (*ground truth*) untuk menyusun *confusion matrix* secara manual (Simoes et al., 2021). Hasil analisis menunjukkan bahwa akurasi time series tertinggi pada parameter OA diperoleh pada skema satu kali clustering dengan 100 epoch, mencapai 98,5%. Sementara itu, nilai KA tertinggi juga diperoleh pada skema yang sama dengan capaian 97,1%. Untuk akurasi citra hasil klasifikasi (*raster classification accuracy*), nilai OA tertinggi sebesar 87% dicapai pada skema satu kali clustering dengan 100 epoch. Nilai KA tertinggi untuk metode ini sebesar 83%, diperoleh pada epoch 100 dan 200. Sebaliknya, akurasi terendah terjadi pada epoch 150 dan 250. Pada percobaan dengan dua kali clustering, nilai OA dan KA menunjukkan variasi, di mana akurasi tertinggi untuk OA ditemukan pada epoch 100 dan 300, dengan hasil yang sama. Demikian pula, nilai Kappa Accuracy tertinggi pada metode ini juga terjadi pada epoch 100 dan 300.

Tabel 3 Hasil Uji Akurasi Setiap Skema dan *Epoch*

Epoch	*Time Series*				Klasifikasi Citra			
	OA		KA		OA		KA	
	SC (%)	DC (%)	SC (%)	DC (%)	SC (%)	DC (%)	SC (%)	DC (%)
100	98,5	97	97,1	96	87	77	83	71
150	91,9	98,5	89,5	98	73	70	54	63
200	95,6	98,6	94,5	98,3	87	73	83	67
250	95,5	97,1	94,3	96,1	73	70	67	63
300	97,1	96,7	96,3	95,7	85	77	83	71

Perbandingan antar skema menunjukkan bahwa satu kali clustering menghasilkan akurasi yang lebih tinggi dibandingkan dua kali clustering. Hal ini disebabkan oleh berkurangnya jumlah sampel akibat proses filtering pada skema dua kali clustering, yang mengurangi jumlah data pada tahap training sehingga kualitas model menurun. Pada skema SC_E100, perolehan *User's Accuracy* (UA) dan *Producer's Accuracy* (PA) untuk masing-masing kelas adalah sebagai berikut: Jagung: UA = 100%, PA = 67%, F1-score = 80%; Kelapa: UA = 80%, PA = 67%, F1-score = 73%; Non-Tanaman: UA = 86%, PA = 100%, F1-score = 92%; Pisang: UA = 75%, PA = 100%, F1-score = 86%; Tanaman Lain: UA = 100%, PA = 100%, F1-score = 100%. Sebagai tambahan, ditampilkan confusion matrix dari skema SC E100 pada Tabel 4. Secara umum, nilai rata-rata akurasi pada skema satu kali clustering lebih tinggi dibandingkan skema dua kali clustering. Faktor utama yang memengaruhi perbedaan ini adalah jumlah dan kualitas data sampel. Hasil penelitian ini membuktikan bahwa penerapan metode ResNet dalam klasifikasi penginderaan jauh berbasis *time-series* dapat memberikan hasil yang sangat baik, dengan capaian akurasi di atas 80%. Temuan ini menunjukkan bahwa metode tersebut memiliki potensi besar sebagai alternatif untuk mempercepat proses pemetaan jenis tanaman di wilayah Indonesia.

Tabel 4 *Confusion Matrix* skema SC E100

Kelas	J	K	NT	P	TL	Σ	UA
J (Jagung)	4	0	0	0	0	4	100%
K (Kelapa)	1	4	0	0	0	5	80%
NT (Non-Tan)	1	0	6	0	0	7	86%
P (Pisang)	0	2	0	6	0	8	75%
TL (Tan L.)	0	0	0	0	6	6	100%
Σ	6	6	6	6	6	30	
PU (%)	67%	67%	100%	100%	100%		

IV. KESIMPULAN

Kesimpulan penelitian ini menunjukkan bahwa klasifikasi penginderaan jauh berbasis time series dengan model ResNet efektif untuk pemetaan jenis tanaman di Indonesia, dibuktikan dengan akurasi 87% yang melampaui standar minimum 85% untuk pemetaan tutupan lahan (Sutanto, 2010). Pada skenario eksperimen yang digunakan dalam penelitian ini, skema klasifikasi dengan dua kali

clustering tidak menunjukkan peningkatan kinerja dibandingkan dengan satu kali *clustering*, yang diduga berkaitan dengan berkurangnya jumlah data sampel yang dapat dimanfaatkan dalam proses pemodelan. Temuan ini bersifat kontekstual terhadap karakteristik dataset, jumlah dan distribusi sampel, serta konfigurasi eksperimen yang diterapkan, sehingga hasilnya tidak dapat digeneralisasi secara langsung ke wilayah, data, atau skenario pemodelan yang berbeda. Selain itu, hasil penelitian juga menunjukkan bahwa peningkatan jumlah *epoch* tidak selalu diikuti oleh peningkatan akurasi, karena kualitas dan kuantitas sampel, ketepatan identifikasi kelas, serta strategi rekayasa fitur memiliki peran yang signifikan dalam menentukan kinerja model klasifikasi.

UCAPAN TERIMA KASIH

Penulis Mengucapkan Terimakasih Kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Yang Telah Memberikan Dana Hibah Penelitian (1483dl/IT9.2.1/PT.01.03/2025) Melalui "Hibah Penelitian Bima Kemdiktisaintek 2025".

KONFLIK KEPENTINGAN

Penulis menyatakan tidak terdapat konflik kepentingan.

PERNYATAAN PENDANAAN

Penelitian ini tidak memperoleh pendanaan khusus.

PERNYATAAN PENGGUNAAN AI GENERATIF DAN TEKNOLOGI BERBASIS AI

GPT hanya digunakan untuk mengoreksi kesalahan tata bahasa dan tipografi. Penulis bertanggung jawab penuh atas isi dan integritas publikasi.

DAFTAR PUSTAKA

Anggara, O., Welly, T. K., Fauzi, A. I., Alif, S. M., Perdana, R. S., Oktarina, S. W., Nuha, M. U., & Rosadi, U. (2023). Monitoring ground deformation of Sinabung volcano eruption 2018-2019 using DInSAR technique and GPS data. *Proceedingofthe7thInternationalConferenceonScienceandTechnology*, 050012. https://doi.org/10.1063/5.0114428

Çakmakçı, R., Salık, M. A., & Çakmakçı, S. (2023). Assessment and Principles of Environmentally Sustainable Food and Agriculture Systems. *Agriculture*, *13*(5), 1073. https://doi.org/10.3390/agriculture13051073

Chaddad, F., Mello, F. A. O., Tayebi, M., Safanelli, J. L., Campos, L. R., Amorim, M. T. A., Barbosa de Sousa, G. P., Ferreira, T. O., Ruiz, F., Perlatti, F., Greschuk, L. T., Rosin, N. A., Fim Rosas, J. T., & Demattê, J. A. M. (2022). Impact of mining-induced deforestation on soil surface temperature and carbon stocks: A case study using remote sensing in the Amazon rainforest. *Journal of South American Earth Sciences*, *119*, 103983. https://doi.org/10.1016/j.jsames.2022.103983

Dharmawan, I. A., Rahadianto, M. A. E., Henry, E., Endyana, C., & Aufaristama, M. (2021). Application of High-Resolution Remote-Sensing Data for Land Use Land Cover Mapping of University Campus. *The Scientific World Journal*, *2021*, 1–17. https://doi.org/10.1155/2021/5519011

Fauzi, A. I., Azizah, N., Yati, E., Atmojo, A. T., Rohman, A., Putra, R., Rahadianto, M. A. E., Ramadhanti, D., Ardani, N. H., Robbani, B. F., Nuha, M. U., Perdana, A. M. P., Sakti, A. D., Aufaristama, M., & Wikantika, K. (2023). Potential Loss of Ecosystem Service Value Due to Vessel Activity Expansion in Indonesian Marine Protected Areas. *ISPRS International Journal of Geo-Information*, *12*(2), 75. https://doi.org/10.3390/ijgi12020075

He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep Residual Learning for Image Recognition* (hlm. 770–778). http://image-net.org/challenges/LSVRC/2015/

Ilyas, I., Isnaini, E. L., Nuha, M. U., Perdana, A. M. P., & Nurhayati, M. (2024a). Pemutakhiran Peta Foto Udara Desa Girimulyo untuk Mendukung Pengembangan Desa Agroforestri Berbasis Informasi Geospasial. *Jurnal Pengabdian Masyarakat Bangsa*, *2*(1), 70–76. https://doi.org/10.59837/jpmba.v2i1.774

Ilyas, I., Isnaini, E. L., Nuha, M. U., Perdana, A. M. P., & Nurhayati, M. (2024b). Pemutakhiran Peta Foto Udara Desa Girimulyo untuk Mendukung Pengembangan Desa Agroforestri Berbasis Informasi Geospasial. *Jurnal Pengabdian Masyarakat Bangsa*, *2*(1), 70–76. https://doi.org/10.59837/JPMBA.V2I1.774

Ivanka, R., Atalla, F., Dita Limbong, A., & Simarmata, T. (2024). Assessing the Current State and Future Trends of Land Use Conversion: Implications for Food Security in Indonesia. *International Journal of Life Science and Agriculture Research*, *3*(4). https://doi.org/10.55677/ijlsar/V03I4Y2024-10

Karimidastenaei, Z., Avellán, T., Sadegh, M., Kløve, B., & Haghighi, A. T. (2022). Unconventional water resources: Global opportunities and challenges. *Science of The Total Environment*, *827*, 154429. https://doi.org/10.1016/j.scitotenv.2022.154429

Kurnianto, B. T. (2024). The Future of Agriculture in Indonesia: Facing Climate Change and Globalization. *West Science Agro*, *2*(04), 171–177. https://doi.org/10.58812/wsa.v2i04.1309

Maulu, S., Hasimuna, O. J., Mutale, B., Mphande, J., & Siankwilimba, E. (2021). Enhancing the role of rural agricultural extension programs in poverty alleviation: A review. *Cogent Food & Agriculture*, *7*(1). https://doi.org/10.1080/23311932.2021.1886663

Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review. *Remote Sensing*, *13*(13), 2450. https://doi.org/10.3390/rs13132450

Omia, E., Bae, H., Park, E., Kim, M. S., Baek, I., Kabenge, I., & Cho, B.-K. (2023). Remote Sensing in Field Crop Monitoring: A Comprehensive Review of Sensor Systems, Data Analyses and Recent Advances. *Remote Sensing*, *15*(2), 354. https://doi.org/10.3390/rs15020354

Pelletier, C., Webb, G. I., & Petitjean, F. (2019). Temporal Convolutional Neural Network for the Classification of Satellite Image Time Series. *Remote Sensing 2019, Vol. 11, Page 523*, *11*(5), 523. https://doi.org/10.3390/RS11050523

Pratiwik, E., & Rahmayani, D. (2023). Determinants of Agricultural Income to Promote Economic Sustainability in Indonesia. *IOP Conference Series: Earth and Environmental Science*, *1248*(1), 012006. https://doi.org/10.1088/1755-1315/1248/1/012006

Provinsi Lampung Dalam Angka 2021 - Badan Pusat Statistik Provinsi Lampung. (t.t.). Diambil 23 Oktober 2025, dari https://lampung.bps.go.id/id/publication/2021/02/26/443c020eb6a33a394e6d3df4/provinsi-lampung-dalam-angka-2021.html]

Risal, Sandy, A. T., & Partha, M. N. (2022). Strategi Adaptasi Petani Ladang di Kawasan Terdampak Banjir Kelurahan Lempake Kota Samarinda. *geoedusains: Jurnal Pendidikan Geografi*, *3*(1), 25–35. https://doi.org/10.30872/geoedusains.v3i1.1298

Setiawan, A., Ashari, Umam, K., & Amalia, R. A. (2023). Politik Hukum Agraria Indonesia Dalam Arus Globalisasi. *INNOVATIVE: Journal Of Social Science Research*, *3*(5), 10916–10929.

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data 2019 6:1*, *6*(1), 60-. https://doi.org/10.1186/S40537-019-0197-0

Simoes, R., Camara, G., Queiroz, G., Souza, F., Andrade, P. R., Santos, L., Carvalho, A., & Ferreira, K. (2021). Satellite Image Time Series Analysis for Big Earth Observation Data. *Remote Sensing 2021, Vol. 13, Page 2428*, *13*(13), 2428. https://doi.org/10.3390/RS13132428

Singh, B. (2022). Introduction to human nutrition. *Justice and Law Bulletin (JLB)*, *1*, 44–49.

Singh, G., Singh, S., Sethi, G., & Sood, V. (2022). Deep Learning in the Mapping of Agricultural Land Use Using Sentinel-2 Satellite Data. *Geographies*, *2*(4), 691–700. https://doi.org/10.3390/geographies2040042

Sun, T.-T., Su, C.-W., Mirza, N., & Umar, M. (2021). How does trade policy uncertainty affect agriculture commodity prices? *Pacific-Basin Finance Journal*, *66*, 101514. https://doi.org/10.1016/j.pacfin.2021.101514

Suranny, L. E., Gravitiani, E., & Rahardjo, M. (2022). Impact of climate change on the agriculture sector and its adaptation strategies. *IOP Conference Series: Earth and Environmental Science*, *1016*(1), 012038. https://doi.org/10.1088/1755-1315/1016/1/012038

Sutanto, S. (2010). REMOTE SENSING RESEARCH: A User's Perspective. *Indonesian Journal of Geography*, *42*(2). https://doi.org/10.22146/IJG.2287

Venna, S. L., & Romulo, A. (2024). Role of Agriculture on Rural Household Food Security: A Systematic Review from Indonesia. *IOP Conference Series: Earth and Environmental Science*, *1324*(1), 012132. https://doi.org/10.1088/1755-1315/1324/1/012132

Wu, B., Zhang, M., Zeng, H., Tian, F., Potgieter, A. B., Qin, X., Yan, N., Chang, S., Zhao, Y., Dong, Q., Boken, V., Plotnikov, D., Guo, H., Wu, F., Zhao, H., Deronde, B., Tits, L., & Loupian, E. (2023). Challenges and opportunities in remote sensing-based crop monitoring: a review. *National Science Review*, *10*(4), 1–17. https://doi.org/10.1093/nsr/nwac290

Wu, W., Huo, L., Yang, G., Liu, X., & Li, H. (2025). Research into the Application of ResNet in Soil: A Review. *Agriculture*, *15*(6), 661. https://doi.org/10.3390/agriculture15060661

Zhang, H., Liu, W., Niu, H., Yin, P., Dong, S., Wu, J., Li, E., Zhang, L., & Zhu, C. (2024). Land Cover Change Detection Based on Vector Polygons and Deep Learning With High-Resolution Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, *62*, 1–18. https://doi.org/10.1109/TGRS.2023.3346968

Zhang, H., Wang, L., Tian, T., & Yin, J. (2021). A Review of Unmanned Aerial Vehicle Low-Altitude Remote Sensing (UAV-LARS) Use in Agricultural Monitoring in China. *Remote Sensing*, *13*(6), 1221. https://doi.org/10.3390/rs13061221

Zhao, Y., Zhang, X., Feng, W., & Xu, J. (2022). Deep Learning Classification by ResNet-18 Based on the Real Spectral Dataset from Multispectral Remote Sensing Images. *Remote Sensing*, *14*(19), 4883. https://doi.org/10.3390/rs14194883

Zhuo, Z., & Zhou, Z. (2021). Remote Sensing Image Retrieval with Gabor-CA-ResNet and Split-Based Deep Feature Transform Network. *Remote Sensing*, *13*(5), 869. https://doi.org/10.3390/rs13050869