



Klasifikasi Tutupan Lahan Sawah dan Kelapa Sawit Menggunakan GLCM dan K-Nearest Neighbor Pada Citra Udara

Nabila Fitriani¹, Dano Fadilah Amelya Rizki², Saffiana Agustin³
^{1,2,3}Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Gresik
¹nabila.fitriani@gmail.com, ²danoamel@gmail.com, ³soffiana@umg.ac.id

Abstract

This study aims to automatically classify rice field and oil palm land cover based on aerial imagery by utilizing the Gray Level Co-occurrence Matrix (GLCM) for texture feature extraction and the K-Nearest Neighbor (KNN) algorithm as the classification method. The dataset consists of 130 training images and 111 test images. The images were processed through cropping and grayscale conversion, followed by texture feature extraction including contrast, correlation, energy, and homogeneity. These features serve as the foundation for distinguishing the unique texture patterns of each land type.

The test results show that the K parameter in KNN significantly affects the classification accuracy, with K=7 achieving the best result of 97.30%. Evaluation using a confusion matrix reinforces the effectiveness of the method in distinguishing the two land cover classes. The combination of GLCM and KNN proves to be both efficient and accurate, with great potential to be applied in automated mapping and monitoring systems, particularly in agricultural and plantation contexts.

Keywords: Land Cover Classification, GLCM, KNN, Aerial Imagery, Rice Fields, Oil Palm

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan tutupan lahan sawah dan kelapa sawit secara otomatis berdasarkan citra udara dengan memanfaatkan metode Gray Level Co-occurrence Matrix (GLCM) untuk ekstraksi fitur tekstur dan algoritma K-Nearest Neighbor (KNN) sebagai metode klasifikasi. Data yang digunakan terdiri dari 130 citra latih dan 111 citra uji. Citra yang telah diproses melalui tahapan cropping dan konversi grayscale kemudian diekstrak fitur teksturnya, meliputi contrast, correlation, energy, dan homogeneity. Fitur ini menjadi dasar bagi proses klasifikasi dalam membedakan pola tekstur khas dari kedua jenis lahan.

Hasil pengujian menunjukkan bahwa nilai parameter K pada KNN memengaruhi tingkat akurasi, dengan K=7 memberikan hasil terbaik sebesar 97,30%. Evaluasi menggunakan confusion matrix memperkuat efektivitas metode dalam membedakan dua kelas tutupan lahan. Kombinasi GLCM dan KNN terbukti efisien dan akurat, serta berpotensi diterapkan dalam sistem pemantauan dan pemetaan otomatis berbasis citra, khususnya di bidang pertanian dan perkebunan.

Kata kunci: Klasifikasi Tutupan Lahan, GLCM, KNN, Citra Udara, Sawah, Kelapa Sawit.

1. Pendahuluan

Perkembangan teknologi penginderaan jauh telah membuka peluang besar dalam pemetaan dan pemantauan wilayah pertanian. Salah satu tantangan utama dalam hal ini adalah mengidentifikasi jenis tutupan lahan, seperti lahan sawah dan kebun kelapa sawit, dengan akurasi tinggi menggunakan data citra udara. Citra dari drone (UAV) maupun satelit mampu memberikan informasi visual berkualitas tinggi yang sangat kaya akan fitur spasial dan tekstur. Namun, pemrosesan citra digital memerlukan metode yang

mampu mengekstrak informasi tekstur secara akurat. Salah satu teknik yang umum digunakan dalam ekstraksi tekstur adalah Gray Level Co-occurrence Matrix (GLCM). GLCM bekerja dengan menghitung hubungan spasial antar piksel dan menghasilkan parameter-parameter seperti kontras, homogenitas, entropi, energi, disimilaritas, dan korelasi, yang dapat digunakan sebagai fitur dalam proses klasifikasi [1][2].

Dalam implementasinya, GLCM sering digabungkan dengan algoritma K-Nearest Neighbor (KNN), yang

mengklasifikasikan objek berdasarkan kemiripan jarak antar fitur yang telah diekstrak [3][4][5]. Kombinasi GLCM dan KNN telah digunakan secara luas dalam berbagai bidang, termasuk klasifikasi pola kain, tekstur permukaan, hingga identifikasi objek pada citra digital. Penggunaan parameter GLCM dengan orientasi sudut berbeda (0° , 45° , 90° , 135°) terbukti memberikan pengaruh signifikan terhadap akurasi klasifikasi, bahkan dalam kasus citra tekstur kompleks. Dalam konteks pertanian dan perkebunan, citra dari satelit resolusi tinggi seperti IKONOS juga telah digunakan untuk membedakan usia tanam pohon kelapa sawit. [6] menggabungkan deep learning dengan data panchromatic IKONOS dan berhasil mencapai akurasi klasifikasi hingga 94,74% untuk membedakan usia tanam sawit [7][8].

Tak hanya itu, studi oleh [9] menggunakan kombinasi CNN dan GLCM untuk klasifikasi tutupan lahan dari citra satelit Sentinel-2 di wilayah Semarang, Jawa Tengah. Penelitian tersebut menunjukkan keberhasilan klasifikasi tujuh kelas tutupan lahan dengan akurasi keseluruhan 98,4%. Dengan melihat potensi besar dari penelitian sebelumnya oleh [10] yang menggunakan metode KNN, serta bukti empiris dari berbagai studi lainnya, penelitian ini diarahkan untuk mengembangkan sistem klasifikasi otomatis berbasis citra udara guna membedakan lahan sawah dan kebun kelapa sawit secara akurat dan efisien.

2. Metode Penelitian

Bagian ini menjelaskan tahapan-tahapan yang dilakukan dalam penelitian klasifikasi tutupan lahan perkebunan kelapa sawit dan sawah berdasarkan citra satelit. Penelitian ini menggunakan pendekatan supervised learning dengan metode klasifikasi K-Nearest Neighbor (K-NN) yang didahului oleh tahapan ekstraksi fitur tekstur menggunakan Gray Level Co-occurrence Matrix (GLCM). Metodologi ini dipilih karena kombinasi antara GLCM dan K-NN telah terbukti efektif dalam mengidentifikasi objek tutupan lahan dengan akurasi yang baik pada penelitian sebelumnya [11][12][13].


Penelitian ini terdiri atas tiga tahap utama, yaitu pengumpulan dan pemilihan data citra, proses ekstraksi fitur, serta klasifikasi dengan metode K-NN. Citra yang digunakan berasal dari area tertentu yang mencakup lahan sawah dan kelapa sawit, yang kemudian diproses dan dianalisis untuk membedakan kedua jenis tutupan lahan tersebut secara otomatis.

2.1. Data dan Area Citra Penelitian

Tutupan lahan merujuk pada kondisi fisik yang tampak di permukaan bumi. Tutupan ini mencakup unsur-unsur seperti vegetasi, tanah kosong, batuan, dan badan air yang berada di atas permukaan tanah. Secara umum, istilah ini juga mengacu pada penutup biofisik yang dapat diamati secara langsung di permukaan bumi [14] [15][16]. Dalam penelitian ini, digunakan

dua jenis citra udara untuk mewakili dua kelas tutupan lahan, yaitu sawah dan perkebunan kelapa sawit. Keduanya dipilih karena memiliki ciri visual yang kontras dan dapat diidentifikasi dengan jelas melalui pengolahan citra. Penelitian terdahulu telah membuktikan efektivitas metode klasifikasi digital dalam membedakan jenis tutupan lahan pada wilayah pertanian dan hutan, seperti yang dilakukan [17]

Citra sawah diperoleh dari platform berbagi gambar bebas lisensi Pexels, yang menyediakan foto udara berkualitas tinggi dengan sudut pandang vertikal. Citra dipilih berdasarkan kejernihan tampilan, minim gangguan awan, dan mampu menampilkan pola petak-petak lahan pertanian basah dengan irigasi yang khas. Sementara itu, citra kelapa sawit menggunakan data resolusi tinggi dari sensor Ikonos yang telah digunakan dalam penelitian terdahulu oleh [6] dengan tampilan pola tanam teratur dan vegetasi homogen khas perkebunan intensif [18].



Gambar 1. Citra RGB yang digunakan sebagai data input untuk klasifikasi tutupan lahan: (a) sawah dengan ciri pola teratur; (b) kelapa sawit dengan tekstur lebih rapat dan gelap

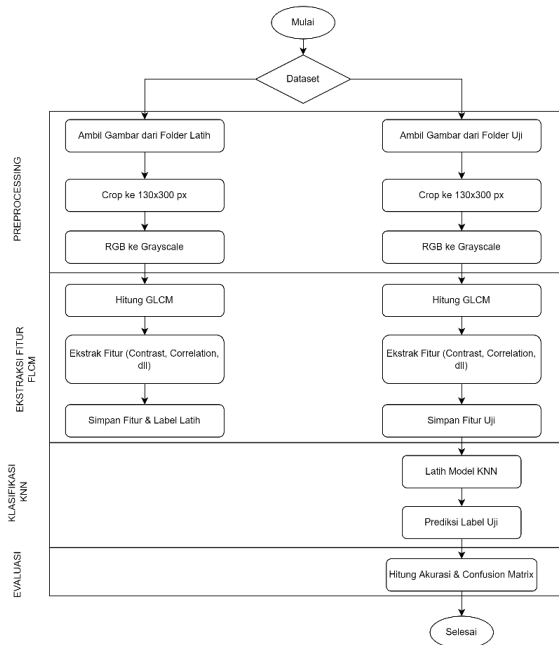
Kedua jenis citra ini yang dapat dilihat pada gambar 1 dipilih karena perbedaan karakteristik tekstur dan pola yang signifikan, sehingga sesuai untuk proses ekstraksi fitur menggunakan metode Gray Level Co-occurrence Matrix (GLCM). Fitur yang diekstrak kemudian digunakan dalam proses klasifikasi otomatis menggunakan algoritma K-Nearest Neighbor (K-NN).

Kombinasi antara tekstur visual yang jelas dan teknik klasifikasi ini diharapkan mampu memberikan hasil identifikasi tutupan lahan yang akurat.

2.2. Alur proses Penelitian

Proses klasifikasi yang diterapkan dalam penelitian ini secara umum mengikuti tahapan berikut: (1) Pengambilan data citra dari folder pelatihan dan pengujian, (2) Pemotongan (cropping) citra menjadi ukuran 130x300 piksel diikuti dengan konversi dari RGB ke grayscale, (3) Ekstraksi fitur tekstur menggunakan metode Grey Level Co-occurrence Matrix (GLCM), dengan parameter seperti Homogeneity, energy, kontras dan korelasi, (4) Penyimpanan hasil ekstraksi fitur beserta label kelas untuk data latih, (5) Pelatihan model klasifikasi menggunakan algoritma K-Nearest Neighbor (KNN), (6) Pengujian model terhadap data uji untuk melakukan prediksi kelas, (7) Evaluasi performa model dilakukan melalui perhitungan tingkat akurasi dan penyusunan confusion matrix.

Rangkaian tahapan tersebut tergambar secara visual dalam Gambar 2.



Gambar 2. Flowchart proses klasifikasi citra lahan menggunakan metode GLCM dan K-Nearest Neighbor (K-NN)

2.3. Proses Klasifikasi Dengan KNN

Penelitian ini menerapkan pendekatan klasifikasi terawasi untuk membedakan jenis penutup lahan berdasarkan fitur citra yang telah diekstraksi sebelumnya. Model dibangun menggunakan data pelatihan yang telah ditentukan kelasnya, sehingga algoritma dapat mengenali pola karakteristik tiap kategori lahan. Metode K-Nearest Neighbor (KNN) digunakan sebagai teknik klasifikasi utama, di mana setiap sampel uji diklasifikasikan berdasarkan kemiripan dengan sejumlah data latih terdekat, yang dihitung menggunakan jarak Euclidean. Perhitungan jarak antar data dalam ruang fitur dirumuskan sebagai berikut pada persamaan 1:

$$distance = \sqrt{\sum_{i=1}^n (x_{training\ i} - x_{testing\ i})^2} \dots\dots\dots(1)$$

Untuk,

distance = jarak antara data training ke data testing

$x_{training\ i}$ = data training ke-i

$x_{testing\ i}$ = data testing ke-i

n = banyaknya data

Untuk mengetahui pengaruh jumlah tetangga terhadap akurasi model, parameter K divariasikan menjadi 3, 5, dan 7. Nilai K yang lebih kecil cenderung sensitif terhadap noise, sementara nilai K yang lebih besar dapat memperhalus keputusan klasifikasi. Seluruh hasil prediksi diuji menggunakan confusion matrix untuk mengevaluasi kinerja model dalam membedakan antara citra sawah dan perkebunan kelapa sawit,

berdasarkan pola tekstur dari fitur GLCM yang telah diolah sebelumnya.

2.4. Metode Evaluasi Klasifikasi

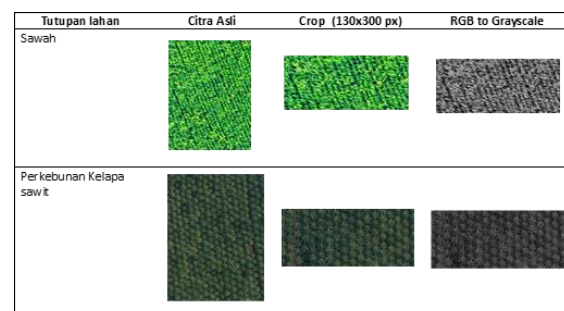
Evaluasi dalam penelitian ini dilakukan menggunakan pendekatan confusion matrix. Metode ini berfungsi sebagai alat analisis untuk menilai seberapa akurat model klasifikasi dalam membedakan data berdasarkan kelasnya [19]. Nilai True Positive (TP) dan True Negative (TN) merepresentasikan jumlah sampel yang berhasil dikenali secara tepat sesuai kelas aslinya. Sebaliknya, False Positive (FP) dan False Negative (FN) mencerminkan jumlah prediksi yang tidak tepat, di mana model salah mengidentifikasi kelas suatu data. Keempat metrik ini digunakan untuk mengevaluasi seberapa andal model dalam membedakan antar kategori dalam klasifikasi.

3. Hasil dan Pembahasan

Pembahasan dalam bab ini terdiri atas tiga bagian utama, yaitu tahap pra-pemrosesan (preprocessing) yang mencakup penyiapan dan pengolahan awal citra, tahap pemrosesan (processing) berupa ekstraksi fitur dan klasifikasi, serta tahap evaluasi yang bertujuan untuk menilai akurasi dan performa klasifikasi berdasarkan confusion matrix dan metrik evaluasi lainnya.

3.1. Preprocessing

Tahap ini mencakup proses awal untuk menyiapkan data sebelum dilakukan klasifikasi. Data citra dikumpulkan dari dua sumber: citra sawit dan citra sawah. Dataset terdiri atas 64 citra sawit dan 66 citra sawah yang digunakan sebagai data latih, serta 111 citra campuran sebagai data uji. Seluruh citra dikumpulkan dalam resolusi yang sesuai untuk ekstraksi fitur dan diorganisasi dalam folder masing-masing kelas. Setiap citra dilakukan proses cropping menjadi ukuran 130x300 piksel untuk memfokuskan pada area utama penutup lahan. Setelah itu, citra dikonversi ke grayscale untuk mengurangi kompleksitas warna dan memudahkan ekstraksi fitur tekstur. Dapat dilihat gambaran prosesnya di gambar 3.



Gambar 3. Tahapan Preprocessing Citra Tutupan Lahan dengan Foto Udara

3.2. Processing (ekstraksi fitur)

Tahap pemrosesan dalam penelitian ini meliputi proses ekstraksi fitur dari citra grayscale menggunakan metode Gray Level Co-occurrence Matrix (GLCM). Fitur tekstur yang digunakan mencakup contrast, correlation, energy, dan homogeneity, yang masing-masing mencerminkan perbedaan, keterkaitan, kekuatan energi, dan keseragaman pola dalam citra. Tidak seperti pendekatan GLCM konvensional yang menghitung fitur berdasarkan arah tertentu (misalnya 0°, 45°, 90°, dan 135°), penelitian ini menerapkan pendekatan global, yaitu menghitung nilai rata-rata dari semua arah. Hal ini bertujuan untuk mendapatkan karakteristik tekstur yang lebih umum dan tidak bergantung pada orientasi objek dalam citra.

1	2	3	4
2.0601	0.7863	0.0375	0.6348
2.1762	0.7818	0.0349	0.6272
2.0886	0.7867	0.0329	0.6291
1.7396	0.7946	0.0346	0.6477
1.8440	0.7873	0.0352	0.6424
2.3044	0.7380	0.0310	0.6099
2.4395	0.7118	0.0303	0.6026
2.5731	0.6930	0.0295	0.5963
2.5607	0.7037	0.0301	0.6067
3.1593	0.6398	0.0274	0.5744
2.9691	0.6681	0.0282	0.5897
2.9142	0.6896	0.0303	0.6023
2.8285	0.6778	0.0290	0.5930
2.5180	0.7129	0.0312	0.6163
3.3231	0.6386	0.0268	0.5769
1.0115	0.8861	0.0435	0.7099
1.0663	0.8804	0.0433	0.7049
1.0806	0.8785	0.0406	0.6986
1.1861	0.8631	0.0431	0.6950
1.4705	0.9247	0.0305	0.6612

Gambar 4. Hasil Perhitungan GLCM dengan 4 Fitur

Hasil ekstraksi fitur ini disusun dalam bentuk tabel numerik, di mana setiap baris mewakili satu citra, dan kolom berisi nilai keempat fitur tekstur tersebut. Dalam gambar 4, yang ditampilkan adalah tabel fitur dari data uji, karena data tersebut digunakan sebagai bahan evaluasi model klasifikasi. Penyajian fitur data latih dianggap tidak perlu karena tidak langsung memengaruhi pembacaan hasil klasifikasi, melainkan hanya berfungsi dalam pembentukan model. Penyertaan tabel data uji memudahkan pembaca untuk memahami bagaimana masing-masing citra diuji

dan diklasifikasikan berdasarkan karakteristik teksturnya.

Setelah fitur tekstur diekstrak dan disusun, data tersebut dimasukkan ke dalam model klasifikasi K-Nearest Neighbor (KNN) untuk diprediksi kelasnya. Model yang telah dilatih sebelumnya menggunakan data latih, kemudian mengklasifikasikan data uji berdasarkan kedekatan fitur dengan sejumlah tetangga terdekat. Hasil prediksi dari model ini kemudian dibandingkan dengan label sebenarnya dari

```

labelSebenarnya = ['sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah', ...
'sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah', ...
'sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah', ...
'sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah','sawah', ...
'sawah','sawah', ...
'sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit', ...
'sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit', ...
'sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit', ...
'sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit', ...
'sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit', ...
'sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit','sawit', ...
'sawit','sawit','sawit','sawit','sawit','sawit', ...
'sawah','sawah','sawah':

```

Gambar 5. Label Citra Data Uji

3.3. Evaluasi Klasifikasi

Evaluasi dilakukan untuk menilai kinerja model klasifikasi dalam membedakan antara citra sawah dan kelapa sawit berdasarkan fitur tekstur yang diperoleh dari GLCM. Pengukuran performa dilakukan menggunakan confusion matrix dan perhitungan akurasi. Confusion matrix menunjukkan jumlah prediksi benar dan salah dari masing-masing kelas, yang memberikan gambaran lebih jelas tentang pola kesalahan model. Untuk keperluan visualisasi, satu buah confusion matrix ditampilkan sebagai contoh, yaitu untuk nilai K = 7 pada Gambar 3.4, karena pada percobaan ini menghasilkan akurasi tertinggi.

	Prediksi Citra Sawah	Prediksi Citra Sawit
Citra Asli Sawah	42	3
Citra Asli Sawit	0	66

Gambar 6. Confussion Matrix dengan K=7

Selain visualisasi confusion matrix, dilakukan juga perbandingan akurasi klasifikasi untuk setiap nilai K (K = 3, 5, dan 7). Perbedaan jumlah tetangga yang digunakan dalam KNN memengaruhi sensitivitas model terhadap data sekitar. Tabel berikut merangkum nilai akurasi yang diperoleh untuk masing-masing parameter K. Dari hasil ini dapat dilihat bahwa pemilihan nilai K yang tepat sangat berpengaruh terhadap performa klasifikasi

Nilai K	Akurasi
3	96,40%
5	96,40%
7	97,30%

4. Kesimpulan

Penelitian ini membuktikan bahwa kombinasi metode Gray Level Co-occurrence Matrix (GLCM) dan algoritma K-Nearest Neighbor (KNN) mampu memberikan hasil klasifikasi tutupan lahan yang sangat baik terhadap citra udara sawah dan kelapa sawit. Fitur tekstur seperti contrast, correlation, energy, dan homogeneity yang dihasilkan dari GLCM dapat merepresentasikan perbedaan pola dan tekstur permukaan lahan secara akurat. Citra sawah yang umumnya memiliki pola teratur dengan tekstur basah dapat dibedakan secara signifikan dari citra kebun kelapa sawit yang cenderung lebih rapat, homogen, dan berwarna lebih gelap. Proses preprocessing seperti cropping dan konversi ke grayscale juga berperan penting dalam menghasilkan data yang siap untuk ekstraksi fitur.

Melalui evaluasi performa model menggunakan confusion matrix dan variasi nilai K pada algoritma KNN (K=3, 5, 7), diketahui bahwa nilai K=7 memberikan hasil klasifikasi tertinggi, yaitu sebesar 97,30%. Hasil ini mengindikasikan bahwa pemilihan jumlah tetangga terdekat yang tepat dapat meningkatkan performa prediksi dan meminimalkan kesalahan klasifikasi. Akurasi tinggi yang dicapai dalam penelitian ini menunjukkan bahwa metode ini dapat diandalkan untuk membedakan jenis tutupan lahan secara otomatis, tanpa memerlukan intervensi manual dari pengguna, serta memungkinkan penerapan pada skala yang lebih luas di berbagai wilayah pertanian dan perkebunan.

Secara keseluruhan, pendekatan ini dapat menjadi solusi efisien dalam pengembangan sistem pemetaan dan pemantauan tutupan lahan berbasis citra udara. Dengan dukungan metode pengolahan citra dan pembelajaran mesin yang tepat, informasi spasial penting dapat diekstraksi secara cepat dan akurat untuk mendukung proses pengambilan keputusan di sektor agrikultur, perencanaan wilayah, dan konservasi. Ke depan, penelitian lanjutan dapat mengembangkan model

ini dengan melibatkan citra multispektral atau hyperspektral serta mengeksplorasi teknik klasifikasi lain seperti deep learning untuk meningkatkan ketahanan dan akurasi model terhadap variasi kondisi citra dan lingkungan.

Daftar Rujukan

- [1] M. Melladia, Indah Febri Annisa, and Surya Kharisma Karnefo, "Perancangan Data Mart Analisis Data Nilai Siswa pada SMAN 2 Tebo," *JUMINTAL J. Manaj. Inform. dan Bisnis Digit.*, vol. 3, no. 1, pp. 18–30, 2024, doi: 10.55123/jumintal.v3i1.3501.
- [2] M. F. Mubarak, M. Nasir, and D. Komalasari, "Jaringan Syaraf Tiruan Untuk Memprediksi Penjualan Pakaian Menggunakan Algoritma Backpropagation," *J. Comput. Inf. Syst. Ampera*, vol. 1, no. 1, pp. 29–43, 2020, doi: 10.51519/journalcisa.v1i1.3.
- [3] R. Sakti and A. Daulay, "Analisis Kritis dan Pengembangan Algoritma K-Nearest Neighbor (KNN): Sebuah Tinjauan Literatur," vol. 4, no. 2, pp. 131–141, 2024.
- [4] M. I. Mubarak, U. S. Karawang, T. Timur, U. Esai, and N. Indonesia, "Penerapan algoritma k-nearest neighbor (knn) dalam klasifikasi penilaian jawaban ujian esai," vol. 7, no. 5, pp. 3446–3452, 2023.
- [5] Y. S. Fuansah *et al.*, "Implementasi Metode K-Nearest Neighbor untuk Menentukan Klasifikasi Status Ekonomi Penerima Bantuan," pp. 929–938.
- [6] S. Agustin, H. Tjandrasa, and R. V. H. Ginardi, "Deep Learning-based Method for Multi-Class Classification of Oil Palm Planted Area on Plant Ages Using Ikonos Panchromatic Imagery," *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 10, no. 6, 2020, doi: 10.18517/ijaseit.10.6.12030.
- [7] D. A. Y. Indah Febri Annisa, "Analisa tingkat pendapatan usaha tani kelapa sawit di kecamatan kinali," vol. 02, no. 1, pp. 14–29, 2024.
- [8] F. S. Fitrawati S, M. Ilsan, and R. Rasyid, "ANALISIS EKONOMI DAN PROSPEK PENGEMBANGAN USAHATANI JAGUNG (*Zea mays* L.) DI KABUPATEN BARRU (Studi Kasus di Desa Lalabata, Kecamatan Tanate Rilau)," *Wiratani J. Ilm. Agribisnis*, vol. 6, no. 2, p. 137, 2023, doi: 10.33096/wiratani.v6i2.307.

- [9] E. Miranda and M. Aryuni, "Klasifikasi Tutupan Lahan Menggunakan Convolutional Neural Network pada Citra Satelit Sentinel-2," *SISTEMASI*, vol. 10, no. 2, 2021, doi: 10.32520/stmsi.v10i2.1226.
- [10] F. S. Wahyuni, H. Z. Zah'ro, A. P. Sasmito, and M. Z. Musyafa, "Penerapan Metode K-Nearest Neighbor Untuk Klasifikasi Tutupan Lahan," *Pros. SENIATI*, vol. 7, no. 1, 2023, doi: 10.36040/seniati.v7i1.7936.
- [11] W. D. A. N. Kuesioner, "Teknik Pengumpulan Data," vol. 3, no. 1, pp. 39–47, 2024.
- [12] Mudasir, *Wawancara dan Observasi*, no. July. 2024.
- [13] Stik. M. 'Ulum S. Catur Setyorini, "Studi Literatur : pemberian Air Susu Ibu (ASI) pada primipara Literature," *J. Heal. Res.*, vol. 8, no. 1, pp. 61–80, 2025.
- [14] Mapid, "[GEODATA] Tutupan Lahan Indonesia."
- [15] Pranowo, "Buku Pengolahan Citra Berbasis PDE Dengan OpenCV," pp. i–119, 2015.
- [16] F. Marpaung, F. Aulia, and R. C. Nabila, *Computer Vision Dan Pengolahan Citra Digital*. 2022.
- [17] D. Kosasih, M. Buce Saleh, and L. B. Prasetyo, "Interpretasi Visual dan Digital untuk Klasifikasi Tutupan Lahan di Kabupaten Kuningan, Jawa Barat," *J. Ilmu Pertan. Indones.*, vol. 24, no. 2, 2019.
- [18] Melladia and S. Aprilia, "Aplikasi Sistem Pakar Mendeteksi Zat Berbahaya Pada Plastik Menggunakan Metode Backward Chaining," *J. JUPITER*, vol. 13, no. 1, pp. 19–18, 2021.
- [19] Juan Vincent Elfonda, Vikhory Bagus Wahyu Nugroho, and Tuhu Agung Rachmanto, "Klasifikasi Tutupan Lahan di Kabupaten Trenggalek Menggunakan Google Earth Engine," *J. Kendali Tek. dan Sains*, vol. 2, no. 3, pp. 85–94, 2024, doi: 10.59581/jkts-widyakarya.v2i3.3488.