

Perbandingan Fitur *Handcrafted* dan *Non-Handcrafted* untuk Klasifikasi Kelembapan Tanah

^{1*)}Diah Septiani

Program Studi S1 Sains Data, Telkom University, Purwokerto, Jawa Tengah, Indonesia
E-Mail: diahseptiani@telkomuniversity.ac.id

²⁾Faisal Dharma Adhinata

Program Studi S1 Rekayasa Perangkat Lunak, Telkom University, Purwokerto, Jawa Tengah, Indonesia
E-Mail: faisaldharma@telkomuniversity.ac.id

ABSTRACT

Soil moisture is a crucial parameter in precision agriculture because it impacts irrigation management and crop productivity. Conventional measurement methods using physical sensors have limitations in terms of cost, maintenance, and coverage area. This study aims to compare the performance of handcrafted and non-handcrafted feature approaches in digital image-based soil moisture classification. The handcrafted approach extracts 60 color features consisting of RGB and HSV statistics and HSV histograms, then classifies them using the Random Forest algorithm. The non-handcrafted approach uses the transfer learning- based MobileNetV2 architecture to automatically learn feature representations from raw images. Both methods were tested using the same dataset and experimental protocol to ensure an objective comparison. The experimental results showed that Random Forest achieved an accuracy of 91.05%, higher than MobileNetV2's 87.65%. Confusion matrix analysis indicated that the dominant misclassification occurred between the moderate and wet classes due to the similarity in color distribution. The results show that for limited datasets and problems dominated by color characteristics, handcrafted features can provide more stable and efficient performance than deep learning models. This study emphasizes the importance of selecting a classification method based on data characteristics and computational requirements, rather than solely on model complexity.

Keywords: Soil moisture classification, handcrafted features, Random Forest, MobileNetV2, image processing, transfer learning

PENDAHULUAN

Kelembapan tanah menjadi parameter penting dalam sistem pertanian presisi karena dapat mempengaruhi pertumbuhan tanaman, efisiensi penggunaan air serta produktifitas hasil panen [1], [2]. Kadar kelembapan tanah ini merupakan pendukung pengambilan keputusan pada manajemen irigasi dan konservasi sumber daya air [3]. Pada umumnya, pengukuran kelembapan tanah menggunakan metode konvensional dengan sensor berbasis kapasitif atau resistif yang ditanam secara langsung di dalam tanah [2]. Walaupun memberikan hasil yang akurat, namun metode tersebut mempunyai keterbatasan yaitu berupa biaya instalasi yang cukup tinggi, membutuhkan kalibrasi secara berkala dan wilayah pengukuran terbatas pada titik tertentu [1].

Pada saat ini perkembangan teknologi pengolahan citra serta machine learning menjadi solusi alternatif untuk pendekatan non-kontak dalam memberikan estimasi kelembapan tanah berbasis citra digital [4], [5]. Ciri visual tanah khususnya distribusi warna dan intensitas piksel mempunyai keterkaitan dengan kandungan air tanah [6]. Pada tanah yang mempunyai kadar air cenderung tinggi memiliki ciri warna lebih gelap jika dibandingkan dengan tanah yang kering,

sehingga ciri warna tanah bisa menjadi indikator klasifikasi [7].

Proses ekstraksi ciri atau fitur pada pengolahan citra dapat dilakukan dengan dua pendekatan utama, yakni *handcrafted features* dan *non-handcrafted features* menggunakan deep learning. Perancangan ekstraksi fitur pada *handcrafted* dilakukan secara manual menggunakan statistik warna, histogram, serta tekstur tanah [8], [9]. Metode ini relatif sederhana dan sumber daya komputasi yang dipakai lebih rendah, serta seringkali efektif digunakan pada dataset yang berukuran kecil hingga menengah [10], [11]. Pada pendekatan ini algoritma yang sering digunakan adalah Random Forest karena mampu menangani fitur dengan dimensi rendah dan rentan terhadap overfitting [13].

Pada pendekatan deep learning menggunakan *Convolutional Neural Network* (CNN) dapat mempelajari representasi fitur secara otomatis dari citra [14]. *MobileNetV2* merupakan arsitektur ringan yang banyak digunakan pada klasifikasi citra karena komputasi yang efisien dan mendukung transfer learning [15], [16]. Penelitian sebelumnya memberikan hasil bahwa CNN mampu memberikan performa yang tinggi dalam klasifikasi citra pertanian [17], [18], akan tetapi model *deep learning* pada

umumnya membutuhkan dataset yang besar untuk generalisasi secara optimal [19].

Penelitian sebelumnya yang berkaitan dengan klasifikasi kelembapan tanah pada umumnya berfokus pada pendekatan tertentu, baik menggunakan machine learning berbasis fitur ataupun deep learning berbasis CNN [7], [9], [18]. Tetapi masih sangat terbatas penelitian yang menggunakan perbandingan langsung antara fitur *handcrafted* dengan *non-handcrafted* pada dataset citra tanah yang sama, khususnya pada kondisi dataset dengan jumlah terbatas. Padahal ketika menggunakan kompleksitas model yang lebih tinggi tidak menjamin selalu meningkatkan performa klasifikasi [12], [19].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk membandingkan secara langsung kinerja *handcrafted features* dan *non-handcrafted* dalam klasifikasi kelembapan tanah berbasis citra. Pada pendekatan *handcrafted* menggunakan fitur statistik fitur warna RGB dan HSV serta menggunakan histogram HSV yang menghasilkan 60 fitur dan diklasifikasikan menggunakan Random Forest. Pendekatan *non-handcrafted* menggunakan arsitektur MobileNetV2 berbasis transfer learning. Untuk mendapatkan analisis performa yang komprehensif, evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall* dan *F-1 score*.


Penelitian ini memberikan kontribusi pada perancangan fitur warna yang representative untuk klasifikasi kelembapan tanah, analisis perbandingan antara metode machine learning konvensional dengan *deep learning* menggunakan dataset yang sama, serta evaluasi efektivitas model pada dataset yang terbatas. Hasil penelitian ini diharapkan bisa menjadi referensi dalam pengambilan metode klasifikasi citra tanah yang efisien, akurat dan sesuai dengan kondisi ketersediaan data.

METODE

Metode yang digunakan yang digunakan pada penelitian ini merupakan pendekatan eksperimental untuk membandingkan kinerja metode *handcrafted features* dan *non-handcrafted* dalam klasifikasi kelembapan tanah berbasis citra digital. Tahapan yang dilakukan secara sistematis dimulai dari pengumpulan dataset, *pre-processing*, ekstraksi fitur, dilanjutkan proses pelatihan model hingga evaluasi kinerja.

Kerangka Kerja Penelitian

Gambar 1 menunjukkan kerangka kerja penelitian yang menggambarkan tahapan secara keseluruhan dari input citra hingga tahap terakhir evaluasi.



Gambar 1. Kerangka Kerja Penelitian

Pada penelitian ini menggunakan dataset citra tanah dari beberapa kategori tingkat kelembapan, seperti tanah kering, tanah lembap dan tanah basah. Citra tanah ini dengan kondisi pencahayaan yang relatif terkendali untuk mengurangi variasi intensitas cahaya yang bisa mempengaruhi distribusi warna. Kemudian dataset dibagi menjadi data latih dan data uji dengan rasio 80:20.

Selanjutnya dilakukan tahapan *pre-processing* citra untuk menyeragamkan ukuran serta meningkatkan kualitas citra sebelum tahap ekstraksi fitur. Keseluruhan citra diubah ukurannya menjadi dimensi yang seragam supaya sesuai dengan kebutuhannya saat *pre-processing*. Kemudian, citra yang mula-mula berwarna RGB dikonversikan menjadi HSV agar citra tersebut lebih representatif dalam menggambarkan karakteristik warna pada tingkat kelembapan tanah, utamanya pada komponen *value* yang berhubungan dengan tingkat kecerahan.

Pada pendekatan *handcrafted feature* yang dilakukan, proses ekstraksi ciri dilakukan dengan cara manual berdasarkan karakteristik warna citra. Setiap fitur yang digunakan terdiri dari nilai rata-rata dan standar deviasi dari kanal RGB dan HSV, serta histogram warna HSV dengan konfigurasi (16 x 16 x 16) sehingga menghasilkan total 60 fitur *handcrafted*. Tahap selanjutnya dilakukan klasifikasi menggunakan algoritma *Random Forest*. *Random forest* memiliki kemampuan untuk menangani data dengan dimensi menengah, tahan terhadap overfitting dan

juga mampu menunjukkan performa yang stabil pada berbagai permasalahan klasifikasi citra.

Secara matematis, prediksi akhir *Random Forest* diperoleh berdasarkan *voting* mayoritas dari seluruh pohon keputusan yang dibangun. Persamaan *voting* mayoritas dapat dituliskan sebagai berikut:

$$\hat{y} = \text{mode} \{h_1(x), h_2(x), \dots, h_n(x)\}$$

dengan $\hat{y}$ adalah hasil prediksi akhir, $h_i(x)$ adalah hasil prediksi dari pohon keputusan ke- i , n adalah jumlah pohon keputusan.

Pada penelitian ini model *Random Forest* diuji dengan variasi jumlah pohon ($n_estimators$) yaitu 50, 100, 150, 200, dan 250 untuk menentukan konfigurasi optimal.

Pada pendekatan yang selanjutnya yaitu menggunakan pendekatan *non-handcrafted* dengan menggunakan metode *deep learning* berbasis *Convolutional Neural Network* (CNN) menggunakan arsitektur MobileNetV2 berbasis transfer learning untuk klasifikasi. Berbeda dengan pendekatan *handcrafted*, pendekatan *non-handcrafted* menggunakan citra mentah langsung digunakan sebagai inputan model tanpa dilakukan proses ekstraksi fitur secara manual terlebih dahulu, karena CNN mampu mempelajari representasi fitur secara otomatis langsung dari citra input. Proses utama CNN menggunakan operasi konvolusi untuk menghasilkan *feature map* yang dirumuskan sebagai berikut:

$$S(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n)$$

Dengan $S(i, j)$ adalah nilai pada *feature map* di posisi (i, j) , $I(i, j)$ adalah nilai piksel pada citra input, $K(m, n)$ adalah nilai kernel berukuran $k \times k$.

Setelah konvolusi, digunakan fungsi *Rectified Linear Unit* (ReLU) untuk menambahkan non-linearitas dan mempercepat konvergensi pelatihan.

$$f(x) = \max(0, x)$$

Model *MobileNetV2* yang telah dilakukan pelatihan pada dataset dimanfaatkan sebagai *feature extraction*, selanjutnya lapisan akhir disesuaikan dengan jumlah kelas dalam penelitian ini. Tahapan pelatihan dilakukan dengan menggunakan teknik *fine-tuning* untuk menyesuaikan parameter model terhadap karakteristik citra tanah.

Pada tahap akhir digunakan fungsi softmax untuk menentukan probabilitas kelas kelembapan tanah:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}}$$

dengan $P(y_i)$ adalah probabilitas kelas ke- i , z_i adalah *output neuron*, dan C adalah jumlah kelas klasifikasi.

Pada evaluasi kinerja model dilakukan dengan menggunakan *confusion matrix* serta

metrik akurasi, *precision*, *recall*, dan nilai F1-score.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

dengan TP (*True Positive*), TN (*True Negative*), FP (*False Positive*) dan FN (*False Negative*).

Nilai evaluasi dari pendekatan *handcrafted* dan *non-handcrafted* dibandingkan serta dianalisis efektifitas dari masing-masing model dalam klasifikasi tingkat kelembapan tanah. Hasil perbandingan yang didapatkan tersebut digunakan sebagai penentu pendekatan yang lebih optimal berdasarkan performa klasifikasi.

HASIL DAN PEMBAHASAN

Pada bagian ini menyajikan hasil kinerja pendekatan *handcrafted features* menggunakan klasifikasi *Random Forest* dan pendekatan *non-handcrafted features* menggunakan MobileNetV2 berbasis *transfer learning* dalam klasifikasi kelembapan tanah.

Hasil Klasifikasi Random Forest


Pada pendekatan fitur *handcrafted* dilakukan dengan menggunakan 60 fitur yang terdiri dari 12 fitur statistik warna (mean dan standar deviasi RGB dan HSV) dan 48 fitur histogram HSV (16,16,16). Pengujian klasifikasi menggunakan *Random Forest* dengan variasi jumlah pohon.

Tabel 1. Pengaruh Jumlah Pohon terhadap Akurasi Random Forest

Jumlah Pohon	Akurasi
50	90,79 %
100	91,05%
150	91,01%
200	91,05%
250	90,83%

Dari tabel 1, hasil yang diperoleh menunjukkan akurasi tertinggi pada konfigurasi 100 dan 200 pohon yaitu dengan nilai akurasi sebesar 0,9105 (91,05%). Nilai ini merupakan nilai yang lebih tinggi ketika dibandingkan dengan konfigurasi lainnya, akan tetapi perbedaannya tidak signifikan, yang menunjukkan bahwa model telah mencapai kondisi yang stabil.

Pada gambar 2 memperlihatkan hasil *Confusion matrix* Random Forest.



Gambar 2. Confusion Matrix Random Forest


Berdasarkan hasil yang diperoleh, model mampu mengklasifikasikan kelas *dry* sejumlah 676 data dengan benar, kelas *moderate* sejumlah 728 data, serta kelas *wet* sejumlah 683 data. Hasil klasifikasi yang salah terbesar terjadi antara kelas *moderate* dan *wet*, yaitu 92 data *wet* yang diprediksi sebagai kelas *moderate*. Kesalahan klasifikasi tersebut menunjukkan bahwa kelas *moderate* dan *wet* mempunyai fitur warna yang relatif mirip, sehingga sulit dibedakan secara sempurna untuk keduanya.

Nilai pada diagonal yang mendominasi dalam *confusion matrix* menunjukkan bahwa karakteristik warna yang digunakan cukup representatif dalam membedakan tingkatan kelembapan pada tanah.

Hasil Klasifikasi MobileNetV2

Pada pendekatan *non-handcrafted* menggunakan MobileNetV2 berbasis transfer learning memperoleh akurasi sebesar 0,8765 (87,65%). Dari hasil akurasi tersebut menunjukkan model *deep learning* mampu mempelajari pola visual kelembapan pada tanah dengan cukup baik, namun performanya masih berada di bawah *Random Forest*.

Pada gambar 3 menunjukkan *confusion matrix MobileNetV2*.




Gambar 3. Confusion Matrix MobileNetV2

Hasil yang diperoleh menunjukkan bahwa kelas *dry* berhasil diklasifikasikan sejumlah 640 data dengan benar, kelas *moderate* sejumlah 676 data serta kelas *wet* sejumlah 693 data. Ketika dibandingkan dengan klasifikasi menggunakan

Random Forest, kesalahan klasifikasi menggunakan *MobileNetV2* relatif lebih tinggi, yaitu pada kelas *moderate* sering tertukar dengan kelas *wet* ataupun *dry*. Dari hasil tersebut dapat diindikasikan bahwa model mengalami kesulitan untuk membedakan tingkat kelembapan tanah.

Analisis Proses Pelatihan MobileNetV2

Pada gambar 4 menunjukkan grafik akurasi dan loss selama proses pelatihan.



Gambar 4. Grafik Training dan Validation pada MobileNetV2

Peningkatan akurasi secara signifikan ditunjukkan pada beberapa epoch awal, dan cenderung stabil pada setelah *epoch* ke-10. Pada pelatihan menunjukkan akurasi lebih dari 0,90 sedangkan untuk akurasi validasi berkisar pada 0,87 sampai dengan 0,88. Ini menunjukkan perbedaan selisih yang kecil untuk performa pelatihan dan validasi.

Penurunan grafik loss secara konsisten ditunjukkan pada saat *training loss* serta *validation loss*, akan tetapi setelah beberapa *epoch validation loss* mulai menunjukkan hasil yang stabil, hal tersebut dapat diindikasikan bahwa model sudah mencapai batas optimal pada dataset yang tersedia. Dengan demikian kenderungan *overfitting* sangat kecil meskipun tidak selalu signifikan.

Perbandingan dan Analisis Komprehensif

Secara keseluruhan, hasil klasifikasi menggunakan pendekatan *Random Forest* dengan fitur *handcrafted* menunjukkan performa yang lebih tinggi ketika dibandingkan dengan klasifikasi menggunakan *MobileNetV2*, yaitu hasil selisih akurasi sekitar 3,4% yang ditunjukkan pada tabel 2. Dengan menggunakan dataset yang relatif terbatas serta permasalahan kelembapan tanah yang sangat dipengaruhi oleh distribusi

warna, pendekatan berbasis fitur menunjukkan hasil yang lebih eksplisit dibandingkan dengan menggunakan model deep learning yang memiliki kompleksitas parameter lebih besar.

Tabel 2. Perbandingan Performa *Random Forest* dan *MobileNetV2*

Model	Akurasi
<i>Random Forest (Handcrafted)</i>	91,05 %
<i>MobileNetV2 (Transfer Learning)</i>	87,65%
Selisih	3,4%

Pada penelitian ini, keunggulan *Random Forest* dapat dijelaskan oleh beberapa faktor, yaitu fitur warna RGB dan HSV mempunyai korelasi secara langsung pada tingkat kelembapan tanah, sehingga representasi fitur menjadi lebih terarah. *Random forest* mempunyai mekanisme *ensemble* yang dapat meningkatkan stabilitas serta dapat menurunkan risiko terhadap *overfitting*. Model dengan kompleksitas yang lebih rendah dapat menjadi lebih efisien secara komputasi.

Sedangkan untuk *MobileNetV2* mempunyai keunggulan dalam mempelajari representasi fitur secara otomatis dan mempunyai potensi memberikan performa yang lebih baik jika jumlah dataset yang digunakan lebih besar. Akan tetapi, dengan kondisi dataset yang terbatas, model deep learning ini belum mampu mengungguli performa pendekatan *handcrafted*.

Hasil ini menjadi temuan bahwa kompleksitas model tidak selalu berbanding lurus dengan peningkatan performa klasifikasi, serta untuk pemilihan model harus dipertimbangkan terkait dengan karakteristik data, dan ukuran dataset yang digunakan.

KESIMPULAN

Pada penelitian ini mempunyai tujuan untuk membandingkan performa kinerja pendekatan *handcrafted features* dan *non-handcrafted features* dalam pengelompokan kelembapan tanah berbasis citra digital. Pada pendekatan *handcrafted features* menggunakan 60 fitur warna yang meliputi statistik RGB, HSV, dan histogram HSV. Fitur warna tersebut kemudian diklasifikasikan menggunakan algoritma *Random Forest*. Berbeda dengan pendekatan *handcrafted features*, pendekatan *non-handcrafted features* menggunakan arsitektur *MobileNetV2* yang berbasis *transfer learning*.

Hasil eksperimen dengan pendekatan *handcrafted features* menggunakan algoritma *Random Forest* mendapatkan akurasi tertinggi sebesar 91,05%, sedangkan pendekatan *non-handcrafted* mendapatkan akurasi sebesar 87,65%, dengan demikian didapatkan nilai selisih performa akurasi sebesar 3,40%. Hal ini menunjukkan bahwa pada kondisi dataset dengan

jumlah terbatas dan permasalahan yang sangat dipengaruhi oleh ciri warna, pendekatan *handcrafted feature* lebih efektif ketika dibandingkan dengan pendekatan berbasis *deep learning*.

Pada *confusion matrix* dapat dianalisis bahwa kesalahan klasifikasi terbesar terjadi antara kelas *moderate* dan kelas *wet* untuk kedua metode tersebut, ini menunjukkan bahwa tingkat kemiripan karakteristik visual antar tingkat kelembapan tanah sangat berdekatan. Walaupun *MobileNetV2* mempunyai kemampuan dalam mempelajari fitur secara otomatis, kompleksitas model serta kebutuhan data yang lebih besar akan menjadi faktor pembatas dalam penelitian ini.

Merujuk pada hasil tersebut, dapat ditarik kesimpulan bahwa penelitian dengan menggunakan metode klasifikasi tidak selalu bergantung pada tingkat kompleksitas model, namun harus juga mempertimbangkan karakteristik data, dan ukuran dataset. Pada skema dengan dataset terbatas dan dominasi fitur warna, pendekatan *handcrafted* berbasis *Random Forest* bisa menjadi solusi performa optimal.

Sebagai pengembangan penelitian lebih lanjut, dapat mengeksplorasi penggunaan dataset yang jauh lebih besar, menerapkan augmentasi data, dan pengujian arsitektur *deep learning* lainnya agar dapat meningkatkan kemampuan generalisasi model.

DAFTAR PUSTAKA

- [1] X. Zhang, G. Feng, and X. Sun, "Advanced technologies of soil moisture monitoring in precision agriculture: A Review," Dec. 01, 2024, *Elsevier B.V.*
- [2] S. M. Shawon, N. I. Neha, A. N. Jui, N. Dey, and H. T. Zubair, "Advances in soil moisture measurement techniques and prediction using artificial intelligence: An extensive and systematic review," Dec. 01, 2025, *Elsevier B.V.*
- [3] S. Gupta *et al.*, "Smart agriculture using IoT for automated irrigation, water and energy efficiency," *Smart Agricultural Technology*, vol. 12, Dec. 2025
- [4] M. Naeimi, P. Daggupati, and A. Biswas, "Image-based soil characterization: A review on smartphone applications," Dec. 01, 2024, *Elsevier B.V.*
- [5] M. Naeimi *et al.*, "Environmental factors in image-based soil analysis: Interaction effects of moisture, texture, and illumination," *Geoderma*, vol. 463, Nov. 2025
- [6] D. Roy, T. Ghosh, B. Das, R. Jatav, and D. Chakraborty, "Smartphone-based image analysis and interpretable machine learning for soil moisture estimation across diverse Indian soils," *Remote Sens. Appl.*, vol. 39, Aug. 2025
- [7] E. O. Babalola, M. H. Asad, and A. Bais, "Soil Surface Texture Classification Using

- RGB Images Acquired Under Uncontrolled Field Conditions," *IEEE Access*, vol. 11, pp. 67140–67155, 2023
- [8] C. Suneetha, L. S. Kumar, K. Sreenivas, and T. Mitran, "Deep learning-driven soil texture classifier using Landsat 8 images," *Remote Sens. Appl.*, vol. 38, Apr. 2025,
- [9] H. Elmannai and A. D. Al-Garni, "Classification using semantic feature and machine learning: Land-use case application," *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 19, no. 4, pp. 1242–1250, 2021
- [10] M. Latha, M. Vasavi, C. K. Kumar, R. Balamanigandan, J. B. Guttikonda, and R. T. Kumar, "Machine Learning Based Precision Agriculture using Ensemble Classification with TPE Model," *Journal of Machine and Computing*, vol. 4, no. 1, pp. 261–268, Jan. 2024
- [11] A. Verma and P. Patel, "Comparative analysis of handcrafted and deep features for agricultural image classification," *IEEE Access*, vol. 10, pp. 98765–98778, 2022.
- [12] F. Ahmed, T. Hasan, and M. Uddin, "Performance evaluation of ensemble learning for small agricultural datasets," *Expert Systems with Applications*, vol. 195, p. 116594, 2022.
- [13] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [14] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436–444, 2015.
- [15] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted residuals and linear bottlenecks," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 4510–4520.
- [16] A. Howard et al., "Searching for MobileNetV3," in *Proc. IEEE/CVF Int. Conf. Computer Vision (ICCV)*, 2019, pp. 1314–1324.
- [17] T. Nguyen and D. Lee, "Soil image classification using convolutional neural networks and transfer learning," *Remote Sensing*, vol. 13, no. 7, p. 1234, 2021.
- [18] P. Rahman, M. Islam, and S. Rahman, "Deep learning-based agricultural image classification: A comparative study," *Sensors*, vol. 23, no. 5, p. 2456, 2023.
- [19] S. Yadav and K. Mehta, "Comparative study of deep learning and traditional machine learning for environmental image classification," *Ecological Informatics*, vol. 75, p. 102012, 2024.