

Klasifikasi Citra Kebakaran Hutan Menggunakan Arsitektur ResNet-50 Berbasis Transfer Learning

Forest Fire Image Classification Using ResNet-50 Architecture Based on Transfer Learning

Aditya Pratama^{*1}, Candra Gudiato², Denny Primanda³, Weli Zuandi⁴, Wahyu Prayitno⁵

^{1,3} Prodi Sistem Informasi, Universitas Nahdlatul Ulama Kalimantan Barat, Kubu Raya

² Prodi Sistem Informasi, Institut Shanti Bhuna, Bengkayang

^{4,5} Prodi Teknik Lingkungan, Universitas Nahdlatul Ulama Kalimantan Barat, Kubu Raya

e-mail: *¹adityapratamabadra@unukalbar.ac.id, ²candra.gudiato@shantibhuana.ac.id,
³dennyprimanda@unukalbar.ac.id, ⁴welizuandi@unukalbar.ac.id,
⁵wahyuprayitno@unukalbar.ac.id

Abstrak

Kebakaran hutan dan lahan (karhutla) merupakan bencana lingkungan serius yang memerlukan sistem deteksi dini secara akurat dan efisien guna meminimalisir dampak kerusakan. Penelitian ini bertujuan untuk menguji keandalan dan efisiensi arsitektur ResNet-50 berbasis Transfer Learning dalam mengklasifikasikan citra digital kebakaran hutan ke dalam dua kelas biner (wildfire dan nowildfire). Dataset sekunder yang diunduh dari repositori terbuka Kaggle terlebih dahulu melalui tahap pra-pemrosesan, mencakup pemeriksaan integritas data (data integrity check) untuk menangani file gambar yang rusak/korup, perubahan ukuran citra (resizing) menjadi 128×128 piksel, normalisasi nilai piksel, serta teknik augmentasi data acak. Dataset dibagi secara terpisah dengan proporsi rasio 70% data latih (30.250 citra), 15% data validasi (6.300 citra), dan 15% data uji (6.300 citra). Arsitektur ResNet-50 dikombinasikan dengan classification head buatan (Global Average Pooling 2D, Dense Layer 256 unit dengan ReLU, Dropout 0.4, dan Output Sigmoid) serta dilatih selama 5 epoch menggunakan optimizer Adam (default learning rate 1×10^{-3}) dan fungsi kerugian Binary Cross-Entropy Loss. Evaluasi terhadap 6.300 citra uji independen menunjukkan bahwa model mampu mencapai **Akurasi Keseluruhan sebesar 88%**. Model terbukti memiliki sensitivitas tinggi terhadap kelas kebakaran (wildfire) dengan Recall sebesar 0.90 dan F1-Score sebesar 0.90 (berhasil mengenali 3.141 dari 3.480 citra kebakaran secara tepat). Pengujian Receiver Operating Characteristic (ROC) Curve menghasilkan nilai **Area Under Curve (AUC) sebesar 0.92**, yang menegaskan kemampuan pemisahan kelas (class separation ability) yang sangat unggul. Hasil ini membuktikan bahwa pendekatan Transfer Learning berbasis ResNet-50 sangat efektif dan efisien untuk diterapkan sebagai mesin pemrosesan visual utama pada sistem peringatan dini kebakaran hutan.

Kata kunci—Kebakaran Hutan, Klasifikasi Citra, ResNet-50, Transfer Learning, Deep Learning, ROC-AUC.

Abstract

Forest and land fires represent a severe environmental disaster requiring accurate and efficient early detection systems to minimize damage. This study aims to evaluate the reliability and efficiency of the ResNet-50 architecture based on Transfer Learning in classifying digital forest

*fire images into two binary classes (wildfire and nowildfire). Secondary dataset obtained from the open Kaggle repository underwent preprocessing, including a data integrity check to handle corrupted image files, image resizing to 128×128 pixels, pixel normalization, and random data augmentation techniques. The dataset was split into training (70%, 30,250 images), validation (15%, 6,300 images), and testing (15%, 6,300 images) sets. The ResNet-50 base model was combined with a custom classification head (Global Average Pooling 2D, Dense Layer with 256 ReLU units, Dropout 0.4, and Sigmoid Output) and trained for 5 epochs using the Adam optimizer (default learning rate 1×10^{-3}) and Binary Cross-Entropy Loss. Evaluation on 6,300 independent test images showed that the model achieved an **Overall Accuracy of 88%**. The model demonstrated high sensitivity toward the wildfire class, yielding a Recall of 0.90 and an F1-Score of 0.90 (correctly identifying 3,141 out of 3,480 fire images). Furthermore, the Receiver Operating Characteristic (ROC) Curve analysis produced an **Area Under Curve (AUC) of 0.92**, confirming excellent class separation capability. These findings demonstrate that the ResNet-50 Transfer Learning approach is highly effective and computationally efficient for implementation as the core visual engine in forest fire early warning systems.*

Keywords—Forest Fire, Image Classification, ResNet-50, Transfer Learning, Deep Learning, ROC-AUC

1. PENDAHULUAN

Bencana alam merupakan ancaman global yang terus meningkat dan menimbulkan dampak kerugian serius, khususnya di Indonesia yang memiliki tingkat risiko bencana ekologis cukup tinggi. Dalam konteks mitigasi bencana, perkembangan teknologi Artificial Intelligence (AI) dan Deep Learning kini makin luas dimanfaatkan untuk mengoptimalkan efektivitas sistem peringatan dini, pemodelan prediksi, serta pemantauan lingkungan berbasis data. Pemanfaatan AI terbukti membuka peluang besar dalam mempercepat respons darurat dan meminimalisir dampak kerugian ekologis maupun finansial. Meskipun demikian, implementasi AI di lapangan masih menghadapi peneliti pada berbagai tantangan teknis mendasar, seperti keterbatasan kualitas citra visual, kendala ketersediaan data, hingga masalah ketidakseimbangan kelas (class imbalance) yang berpotensi menurunkan keandalan sistem deteksi.

Salah satu isu lingkungan paling krusial di Indonesia yang membutuhkan sistem mitigasi presisi adalah fenomena Kebakaran Hutan dan Lahan (Karhutla). Karhutla umumnya memuncak pada bulan Agustus hingga September yang dipicu oleh durasi musim kemarau panjang. Kejadian ini tercatat secara masif di berbagai wilayah rawan seperti Kabupaten Pelalawan Provinsi Riau (Pratiwi et al., 2021), Kabupaten Ogan Komering Ilir Provinsi Sumatera Selatan (Firmansyah et al., 2024), hingga wilayah Nusa Tenggara Timur (Dwiasnati et al., 2024). Dampak yang ditimbulkan tidak hanya merusak keanekaragaman hayati dan habitat satwa, tetapi juga menghasilkan asap berbahaya yang memicu pencemaran udara regional serta kerugian ekonomi yang luas.

Dalam upaya menyelesaikan masalah pemantauan karhutla, pendekatan konvensional sejauh ini mengandalkan analisis variabel iklim (seperti suhu, kelembaban, dan kecepatan angin) serta titik panas (hotspot) sensor satelit. Beberapa penelitian terdahulu berhasil menerapkan algoritma machine learning statistik untuk memprediksi kemunculan titik panas, seperti penggunaan Naïve Bayes oleh [1] serta metode Random Forest oleh [2]. Namun, isu utama dari pemantauan berbasis indikator numerik ini adalah tingginya risiko ketidakakuratan deteksi (false positive dan missed detection). Sensor titik panas sering kali salah mendeteksi area non-kebakaran sebagai kebakaran (atau sebaliknya), serta tidak mampu memberikan verifikasi kondisi visual fisik secara langsung di lapangan.

Untuk mengatasi keterbatasan data numerik tersebut, sejumlah peneliti mulai mengalihkan fokus pada pemrosesan citra digital menggunakan algoritma Convolutional Neural

Network (CNN). Penelitian oleh [3] membuktikan bahwa model CNN mampu mengklasifikasikan citra asap dan api dengan akurasi tinggi, meskipun citra berkualitas rendah atau kabur di lapangan masih menjadi tantangan. Di sisi lain, ulasan penelitian oleh [4] menemukan isu teknis lain pada CNN konvensional, di mana kemiripan visual antara area terbakar dengan fitur terang (seperti pantulan cahaya matahari atau lahan gundul/kering) sering kali memicu salah klasifikasi.

Isu paling kritis pada penerapan CNN untuk deteksi kebakaran diungkapkan [5]. Penelitian tersebut menunjukkan bahwa model CNN sederhana dapat menghasilkan akurasi semu yang menyesatkan (*deceptive accuracy*) hingga 99%. Namun, ketika dievaluasi menggunakan Confusion Matrix, model tersebut ternyata mengalami kegagalan fatal akibat ketidakseimbangan kelas (*class imbalance*), di mana model gagal mengenali 301 dari 331 titik api yang sebenarnya. Kegagalan mendeteksi titik api nyata ini sangat berbahaya jika diimplementasikan pada sistem peringatan dini bencana [6].


Guna menyelesaikan serangkaian isu teknis tersebut mulai dari kendala fitur visual yang gundul/terang, kegagalan ekstraksi fitur pada citra kabur, hingga masalah *deceptive accuracy* akibat ketidakseimbangan kelas penelitian ini mengusulkan penggunaan pendekatan Transfer Learning berbasis arsitektur ResNet-50. ResNet-50 memiliki keunggulan berupa mekanisme Shortcut Connection (*Residual Learning*) yang memungkinkan pelatihan jaringan saraf tiruan secara lebih mendalam tanpa mengalami penurunan performa (*degradation problem*). Melalui ekstraksi fitur spasial mendalam dari model yang telah terlatih (*pre-trained ImageNet*), ResNet-50 diharapkan mampu membedakan karakteristik visual kompleks secara presisi antara area kebakaran nyata dan non-kebakaran.

Tujuan dari penelitian ini adalah mengembangkan dan mengevaluasi model klasifikasi citra kebakaran hutan biner (*wildfire vs nowildfire*) menggunakan Transfer Learning ResNet-50. Penelitian ini berkontribusi dalam menyediakan solusi deteksi visual yang tidak hanya berakurasi tinggi, tetapi juga sensitif, stabil, dan andal dalam mengenali titik api/asap guna mendukung pengembangan sistem peringatan dini karhutla berbasis kecerdasan buatan.

2. METODE PENELITIAN

2.1 Alur Penelitian

Tahapan penelitian ini dirancang secara sistematis untuk memastikan proses klasifikasi citra asap kebakaran hutan berjalan dengan akurat dan efisien [7]. Alur penelitian secara umum meliputi: pengumpulan dataset, pra-pemrosesan citra (*preprocessing*), pembagian dataset (*data splitting*), augmentasi data, pembentukan arsitektur model (*Transfer Learning ResNet-50*), pelatihan model (*training*), serta evaluasi kinerja model.



Gambar 2.1 Alur Penelitian

2. 2 Dataset dan Sumber data

Dataset yang digunakan dalam penelitian ini terdiri dari citra digital yang terbagi ke dalam 2 kelas (binary classification)[8], yaitu:

1. Asap Kebakaran (Smoke/Fire): Citra yang menampilkan visualisasi asap atau api kebakaran hutan [9].
2. Bukan Asap (Non-Smoke/Clear): Citra kondisi hutan/lingkungan normal tanpa adanya asap kebakaran.

2. 3 Pra-Pemrosesan Citra (Preprocessing)

Sebelum dimasukkan ke dalam model pelatihan, seluruh citra melalui tahap pra-pemrosesan berikut:

1. *Resizing*: Citra diubah ukurannya menjadi 128×128 piksel sesuai dengan standar dimensi input arsitektur ResNet-50.
2. *Normalization*: Nilai piksel citra dinormalisasi ke rentang $[0, 1]$ atau disesuaikan dengan skala *scaling factor* standar ImageNet untuk mempercepat proses konvergensi saat pelatihan.

2. 4 Pembagian Dataset

Dataset dibagi menjadi 3 bagian utama untuk menghindari *overfitting* dan memastikan evaluasi model bersifat objektif:

- Data Latih (*Training Set*): 70% dari total dataset.
- Data Validasi (*Validation Set*): 15% dari total dataset.
- Data Uji (*Test Set*): 15% dari total dataset.

2. 5 Arsitektur Model (Transfer Learning ResNet-50)

Penelitian ini memanfaatkan pendekatan *Transfer Learning* menggunakan arsitektur ResNet-50 yang telah dilatih sebelumnya (*pre-trained*) pada dataset ImageNet[10][11].

1. *Feature Extractor* (Frozen Layer): Seluruh lapisan konvolusi dasar dari ResNet-50 dibekukan (*frozen*), sehingga bobot (*weights*) dasar ImageNet dipertahankan untuk mengekstraksi fitur visual tingkat tinggi (*high-level features*)[12] [13].
2. *Classification Head* (Custom Layer): Di atas *feature extractor*, ditambahkan lapisan kustom berupa:
 - *Global Average Pooling 2D* (GAP) untuk mengurangi dimensi fitur.
 - Lapisan *Dense* dengan fungsi aktivasi ReLU dan *Dropout* (0.5) untuk mencegah *overfitting*.
 - Lapisan *Output Dense* (1 unit) dengan fungsi aktivasi Sigmoid untuk klasifikasi biner (Asap vs. Bukan Asap)[14][15].

2. 6 Parameter Pelatihan Model (Hyperparameters)

Proses pelatihan dilaksanakan dengan pengaturan parameter sebagai berikut:

- Optimizer: Adam dengan *learning rate* awal 1×10^{-4} .
- Loss Function: *Binary Cross-Entropy*.
- Batch Size: 32.
- Jumlah Epoch: 5 Epoch.
 - *Rasionalisasi*: Penggunaan 5 epoch dinilai optimal dan efisien karena ekstraktor fitur ResNet-50 sudah memiliki pembobotan *pre-trained* yang sangat fleksibel dari ImageNet. Hal ini memungkinkan model mencapai titik konvergensi (*loss*

stabil dan akurasi tinggi) secara cepat tanpa memerlukan putaran pelatihan yang banyak.

2.7 Evaluasi Model


Kinerja model diuji menggunakan data uji (*Test Set*) berdasarkan matrik evaluasi dari *Confusion Matrix*:

1. Akurasi (*Accuracy*): Mengukur persentase prediksi yang benar secara keseluruhan.
2. Presisi (*Precision*): Mengukur ketepatan prediksi kelas positif.
3. Recall / Sensitivitas: Mengukur kemampuan model menemukan kembali sampel kelas positif.
4. F1-Score: Rata-rata harmonis antara Presisi dan Recall.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Proses pelatihan model Transfer Learning berbasis arsitektur ResNet-50 dilakukan selama 5 epoch. Perkembangan kinerja model selama proses pembelajaran pada data latih (training set) dan data validasi (validation set) dapat diamati melalui grafik akurasi dan loss pada Gambar 3.1.



Gambar 2. Grafik Peningkatan Akurasi dan Penurunan Loss Pelatihan Model ResNet-50 selama 5 Epoch

3.1.1 Kinerja Akurasi dan Konvergensi

Berdasarkan Gambar 3.1, model menunjukkan peningkatan kinerja yang sangat cepat sejak epoch pertama. Akurasi validasi (*validation accuracy*) berhasil mencapai rentang **87% hingga 88%** (puncak pada ~87.6% di Epoch 4) hanya dalam kurun waktu 5 epoch pelatihan. Tren grafik *validation accuracy* yang konsisten berada di atas *training accuracy* menegaskan bahwa penerapan teknik *Data Augmentation* dan *Dropout* (0.4) berjalan efektif dalam mencegah terjadinya *overfitting*, sehingga model memiliki kemampuan generalisasi data yang sangat baik.

3.1.2 Efisiensi Pendekatan Transfer Learning

Tingginya akurasi yang dicapai dalam jumlah epoch yang sangat singkat ini membuktikan efisiensi dari pendekatan *Transfer Learning*. Dengan memanfaatkan bobot terdistribusi yang telah dilatih sebelumnya (*pre-trained weights*) pada dataset ImageNet, model ResNet-50 tidak perlu mempelajari fitur visual dasar (seperti garis, tepi, tekstur, dan kontras warna) dari nol (*from scratch*). Ekstraktor fitur yang kaya dari ImageNet memungkinkan model langsung fokus pada pemetaan fitur tingkat tinggi (*high-level features*) khusus untuk membedakan karakteristik visual asap/api kebakaran dan vegetasi hutan normal, sehingga mempercepat waktu konvergensi secara signifikan[16].

3.1.3 Evaluasi Menggunakan Data Uji (Test Set)

Guna menguji keandalan model pada data independen yang belum pernah dikenali sebelumnya, evaluasi dilakukan terhadap **6.300 citra uji**. Hasil prediksi model dievaluasi menggunakan *Confusion Matrix* dan matriks performa klasifikasi sebagaimana disajikan pada Tabel 3.1 dan Tabel 3.2.

Tabel 3.1. Confusion Matrix Evaluasi Data Uji (6.300 Sampel)

Kelas Aktual / Prediksi	Prediksi <i>nowildfire</i>	Prediksi <i>wildfire</i>	Total Citra Uji
<i>nowildfire</i>	2.431 (<i>True Negative</i>)	389 (<i>False Positive</i>)	2.820
<i>wildfire</i>	339 (<i>False Negative</i>)	3.141 (<i>True Positive</i>)	3.480
Total	2.770	3.530	6.300

Tabel 3.2. Laporan Klasifikasi Kinerja Model ResNet-50

Kelas Target	Presisi (Precision)	Recall / Sensitivitas	F1- Score	Jumlah Sampel (Support)
<i>nowildfire</i>	0.88	0.86	0.87	2.820
<i>wildfire</i>	0.89	0.90	0.90	3.480
Akurasi Keseluruhan (<i>Accuracy</i>)	—	—	0.88	6.300
Macro Average	0.88	0.88	0.88	6.300
Weighted Average	0.88	0.88	0.88	6.300

Analisis Hasil dan Kesalahan Prediksi (*Error Analysis*)

Berdasarkan Tabel 3.1, model berhasil mengklasifikasikan mayoritas citra uji dengan sangat akurat:

- True Positive (TP = 3.141): Sebanyak 3.141 citra kebakaran hutan berhasil dideteksi secara tepat sebagai kelas *wildfire*.


- True Negative (TN = 2.431): Sebanyak 2.431 citra kondisi hutan normal teridentifikasi dengan benar sebagai kelas nowildfire.

Meskipun demikian, terdapat sebagian kecil kesalahan klasifikasi pada data uji:

1. False Positives (FP = 389): Sebanyak 389 citra non-kebakaran salah diprediksi sebagai kebakaran. Hal ini umumnya dipicu oleh adanya kemiripan visual (*visual ambiguity*) antara pola warna dan tekstur awan tebal, kabut pagi, atau pantulan cahaya matahari yang terang pada area lahan gundul dengan karakteristik kepulan asap kebakaran.
2. False Negatives (FN = 339): Sebanyak 339 citra kebakaran salah terdeteksi sebagai kondisi aman. Kesalahan ini berpotensi terjadi pada citra dengan kepulan asap yang sangat tipis atau citra kebakaran skala kecil yang tertutup oleh kanopi vegetasi yang lebat, sehingga fitur visual api/asap sulit diekstrak oleh model.

3.3 Analisis Receiver Operating Characteristic (ROC) Curve

Evaluasi ambang batas kepastian model dalam memisahkan kedua kelas diukur menggunakan Receiver Operating Characteristic (ROC) Curve sebagaimana ditampilkan pada Gambar 3.2.



Gambar 3.2 Receiver Operating Characteristic (ROC) Curve Model ResNet-50 dengan Nilai AUC sebesar 0.92.

Berdasarkan Gambar 3.2, kurva ROC menunjukkan lengkungan grafik yang sangat mendekati sudut kiri atas (*True Positive Rate* tinggi dengan *False Positive Rate* rendah). Pengujian ini menghasilkan nilai Area Under Curve (AUC) sebesar 0.92.

Nilai AUC sebesar 0.92 (mendekati nilai sempurna 1.00) membuktikan bahwa model ResNet-50 memiliki daya pemisahan kelas (*class separation ability*) yang sangat kuat, stabil, dan reliabel. Performa ini menegaskan bahwa model sangat layak diimplementasikan sebagai basis mesin utama pada sistem peringatan dini (*early warning system*) bencana kebakaran hutan dan lahan.

4. KESIMPULAN

Berdasarkan hasil penelitian dan pengujian klasifikasi citra kebakaran hutan menggunakan arsitektur ResNet-50 berbasis *Transfer Learning*, dapat ditarik beberapa kesimpulan utama sebagai berikut:

1. Kinerja dan Efisiensi Model: Pendekatan *Transfer Learning* berbasis ResNet-50 terbukti sangat efisien. Hanya dengan durasi pelatihan 5 epoch, model mampu mencapai Akurasi Keseluruhan sebesar 88% pada 6.300 data uji independen. Pemanfaatan bobot *pre-trained* ImageNet berhasil mempercepat proses konvergensi tanpa mengorbankan daya generalisasi model.
2. Sensitivitas Deteksi Kebakaran: Model memiliki sensitivitas yang tinggi dalam mengenali citra kebakaran (*wildfire*), yang ditunjukkan oleh nilai *Recall* sebesar 0.90 dan *F1-Score* sebesar 0.90. Dari total 3.480 citra kebakaran pada data uji, sebanyak 3.141 citra berhasil terdeteksi dengan benar (*True Positive*), sehingga mampu menekan risiko kegagalan deteksi (*missed detection*) pada kondisi nyata.
3. Keandalan Pemisahan Kelas: Pengujian *Receiver Operating Characteristic* (ROC) Curve menghasilkan nilai Area Under Curve (AUC) sebesar 0.92. Nilai AUC ini membuktikan bahwa model memiliki kemampuan pemisahan kelas (*class separation ability*) yang sangat baik dan reliabel untuk diterapkan sebagai mesin utama sistem peringatan dini bencana kebakaran hutan.
4. Pentingnya Integrasi Data: Proses pra-pemrosesan berupa pembersihan dataset dari file gambar yang rusak/korup (*corrupted files*) sebelum pelatihan terbukti sangat krusial untuk menjaga kelancaran *pipeline* data dan mencegah kegagalan eksekusi (*error*) di tengah iterasi pelatihan.

5. SARAN

Untuk pengembangan penelitian selanjutnya, disarankan untuk menerapkan teknik fine-tuning dengan membuka pembekuan (*unfreeze*) pada beberapa residual block teratas arsitektur ResNet-50 serta menambah jumlah epoch pelatihan secara bertahap guna mengeksplorasi potensi peningkatan akurasi di atas 90%. Selain itu, pengayaan dataset menggunakan data citra lokal dari wilayah rawan kebakaran hutan dan lahan seperti Kalimantan Barat khususnya karakteristik unik ekosistem lahan gambut, tutupan vegetasi lokal, serta kondisi cuaca daerah tropis sangat penting untuk ditingkatkan agar model memiliki sensitivitas konteks spasial yang lebih tinggi. Penambahan variasi sampel visual yang memiliki kemiripan karakteristik (*visual ambiguity*) dengan asap kebakaran, seperti kabut asap tipis (*haze*), awan tebal, dan pantulan cahaya matahari pada lahan gundul, juga direkomendasikan untuk menekan tingkat False Positive. Terakhir, penelitian mendatang dapat dikembangkan dari skala klasifikasi biner menuju deteksi objek (*Object Detection*) atau segmentasi semantik (*Semantic Segmentation*) agar sistem mampu menandai lokasi spesifik (*bounding box*) dan mengukur luasan sebaran area kebakaran secara real-time.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi (Kemendiknas) atas dukungan pendanaan yang telah diberikan melalui program hibah penelitian ini. Apresiasi dan ucapan terima kasih juga disampaikan kepada Universitas Nahdlatul Ulama Kalimantan Barat (UNU Kalbar) atas fasilitas,

dukungan kelembagaan, serta lingkungan akademik yang kondusif selama pelaksanaan penelitian hingga penyelesaian publikasi ini..

DAFTAR PUSTAKA

- [1] T. A. Pratiwi, M. Irsyad, and R. Kurniawan, "Klasifikasi Kebakaran Hutan dan Lahan Menggunakan Algoritma Naïve Bayes (Studi Kasus: Provinsi Riau)," *Jurnal Sistem dan Teknologi Informasi (Justin)*, vol. 9, no. 2, p. 101, Apr. 2021, doi: 10.26418/justin.v9i2.42823.
- [2] A. Firmansyah, M. F. Syahidin, and Y. S. Triana, "Prediksi Kebakaran Hutan Berdasarkan Titik Panas dan Iklim Menggunakan Algoritma Random Forest," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 10, no. 2, pp. 145–155, Sep. 2024, doi: 10.25077/TEKNOSI.v10i2.2024.145-155.
- [3] Y. Muntarti, Alfi Zahra Muharramah, Fiqrah Idhul Dwi, Yabrina Angelika Rantelili, and Ilham Julian Effendi, "Klasifikasi citra asap kebakaran hutan untuk monitoring lingkungan berbasis CNN," *INFOTECH : Jurnal Informatika & Teknologi*, vol. 6, no. 2, pp. 117–130, Dec. 2025, doi: 10.37373/infotech.v6i2.1645.
- [4] S. Dwiasnati, Y. Devianto, S. M. Arif, and R. Avrizal, "Pemodelan Wilayah Titik Api Kebakaran Hutan Menggunakan Deep Learning," *Jurnal Ilmiah FIFO*, vol. 16, no. 1, p. 1, May 2024, doi: 10.22441/fifo.2024.v16i1.001.
- [5] C. Gudiato, A. Pratama, and C. Cahyaningtyas, "Forest Fire Detection Based on Digital Imagery Using Convolutional Neural Network (CNN) Model," *G-Tech: Jurnal Teknologi Terapan*, vol. 10, no. 2, pp. 845–855, Apr. 2026, doi: 10.70609/g-tech.v10i2.9422.
- [6] Denny Primanda, Nurman Hariyanto, Aditya Pratama, and Adha Maulana, "Mitigasi Karhutla Menggunakan IoT Dengan Pendekatan Zona Fresnel Untuk Optimalisasi Transmisi Data," *SISFOTENIKA*, vol. 15, no. 2, pp. 184–193, Jul. 2025, doi: 10.30700/sisfotenika.v15i2.573.
- [7] A. A. Sukmandhani, Lukas, Y. Heryadi, W. Suparta, and A. Wibowo, "Classification Algorithm Analysis for Breast Cancer," *E3S Web of Conferences*, vol. 388, p. 02012, May 2023, doi: 10.1051/e3sconf/202338802012.
- [8] V. Sathishkumar, J. Cho, M. Subramanian, and O. S. Naren, "Forest fire and smoke detection using deep learning-based learning without forgetting," *Fire Ecology*, vol. 19, pp. 1–17, 2023, doi: 10.1186/s42408-022-00165-0.
- [9] D. Jiang and Y. Peng, "Forest Fire Prediction Model Based on Machine Learning," in *Proceedings of the 2025 5th International Conference on Computational Modeling, Simulation and Data Analysis*, New York, NY, USA: ACM, Dec. 2025, pp. 6–11. doi: 10.1145/3796731.3796733.
- [10] Md. B. Hossain, S. M. H. S. Iqbal, Md. M. Islam, Md. N. Akhtar, and I. H. Sarker, "Transfer learning with fine-tuned deep CNN ResNet50 model for classifying COVID-19 from chest X-ray images," *Inform. Med. Unlocked*, vol. 30, p. 100916, 2022, doi: 10.1016/j.imu.2022.100916.
- [11] H. Rohman, N. Nafi'iyah, and A. A. Bettaliyah, "Tomato Ripeness Classification Using Transfer Learning Approach with ResNet50 CNN Model," *Jurnal Ilmiah Sistem Informasi*, vol. 4, no. 3, pp. 646–659, Nov. 2025, doi: 10.51903/zkncwx43.
- [12] Mariana Purba, "Klasifikasi Jenis Daun Tanaman Tropis Menggunakan Model ResNet50 Berbasis Transfer Learning dengan Dataset Tropical Plant Leaf," *JCOSIS (Journal Computer Science and Information Systems)*, vol. 2, no. 2, pp. 51–57, Oct. 2025, doi: 10.61567/jcosis.v2i2.255.
- [13] M. Padantya Saputra, "Pemanfaatan Kecerdasan Buatan untuk Mitigasi Bencana: Analisis Peluang dan Hambatan," *Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan)*, vol. 8, no. 3, pp. 244–255, May 2025, doi: 10.47970/siskom-kb.v8i3.822.

- [14] C. S. Dengen and A. H. Muhammad, "Implementasi Transfer Learning ResNet-50 dalam Klasifikasi Penyakit Daun Tomat Berbasis CNN," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 4, pp. 3907–3914, Dec. 2025, doi: 10.29100/jupi.v10i4.7191.
- [15] E. Maulidiya, C. Fatichah, N. Suciati, and F. Baskoro, "UAV LAND COVER CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK FEATURE MAP WITH A COMBINATION OF MACHINE LEARNING," *JUTI: Jurnal Ilmiah Teknologi Informasi*, pp. 45–55, Jan. 2024, doi: 10.12962/j24068535.v22i1.a1214.
- [16] S. S.-C. Wang, Y. Qian, L. R. Leung, and Y. Zhang, "Interpreting machine learning prediction of fire emissions and comparison with FireMIP process-based models," *Atmos. Chem. Phys.*, vol. 22, no. 5, pp. 3445–3468, Mar. 2022, doi: 10.5194/acp-22-3445-2022.