



Analisis Deteksi Manipulasi Gambar Menggunakan *Error Level Analysis* dan *Deep Learning* di SD Padedewatu

Herlina Lida Hawa^{1*}, Herman Huki Ratu², Diana Reby Sabawaly^{3*}

¹⁻³Program Teknik Informatika, Universitas Stella Maris Sumba

*Penulis Korespondensi: herlina@gmail.com

Abstract. *Digital images are increasingly used as documentation in educational environments, while image-editing tools make manipulation increasingly accessible. This study analyzes a workflow that combines Error Level Analysis (ELA) and a Convolutional Neural Network (CNN) for preliminary detection of manipulated images using photographs from SD Padedewatu as a case study. The dataset initially consisted of 34 original photographs. Because the supplied photographs did not contain verified manipulation labels, controlled manipulated variants were generated from each source image using copy-move, splicing, and object-erasure operations. The resulting labeled dataset contained 136 images, consisting of 34 authentic and 102 manipulated images. ELA was applied by recompressing each image and visualizing the resulting compression-error differences. A CNN classifier was then trained on ELA representations. To reduce source-image leakage, 24 source-image groups were used for training and 10 source-image groups were reserved for testing, producing 96 training images and 40 testing images. The model achieved 75% test Accuracy, 75% precision, 100% recall, and an F1-score of 85.71%. However, the confusion matrix showed that all test images were predicted as manipulated, including the 10 authentic images. Therefore, the Accuracy value should not be interpreted as evidence of balanced or robust forgery detection. The experiment provides a reproducible local ELA-CNN workflow and identifies dataset balance, sample size, and external validation as important priorities for subsequent research.*

Keywords: *CNN; Digital Image Forensics; Error Level Analysis; Image Manipulation; Image Forgery Detection.*

Abstrak.. Gambar digital semakin banyak digunakan sebagai dokumentasi di lingkungan pendidikan, sementara perangkat pengolah gambar membuat manipulasi citra semakin mudah dilakukan. Penelitian ini menganalisis alur deteksi awal yang menggabungkan *Error Level Analysis* (ELA) dan *Convolutional Neural Network* (CNN) menggunakan foto SD Padedewatu sebagai studi kasus. Dataset awal terdiri atas 34 foto asli. Karena foto yang diberikan belum memiliki label manipulasi yang terverifikasi, setiap foto sumber dibuatkan variasi manipulasi terkontrol menggunakan operasi copy-move, splicing, dan penghapusan objek. Dataset berlabel yang dihasilkan terdiri atas 136 citra, yaitu 34 citra asli dan 102 citra manipulasi. ELA diterapkan dengan melakukan kompresi ulang citra dan memvisualisasikan perbedaan tingkat kesalahan kompresi. Representasi ELA selanjutnya digunakan sebagai masukan CNN. Untuk mengurangi kebocoran data berdasarkan sumber foto, 24 kelompok foto sumber digunakan untuk pelatihan dan 10 kelompok sumber digunakan untuk pengujian, sehingga diperoleh 96 citra pelatihan dan 40 citra pengujian. Model menghasilkan akurasi pengujian 75%, precision 75%, recall 100%, dan F1-score 85,71%. Namun, confusion matrix menunjukkan seluruh citra pengujian diprediksi sebagai manipulasi, termasuk 10 citra asli. Oleh karena itu, nilai akurasi tersebut tidak dapat ditafsirkan sebagai bukti kinerja deteksi manipulasi yang seimbang dan kuat. Eksperimen ini menghasilkan alur ELA-CNN yang dapat direproduksi pada data lokal serta menunjukkan bahwa keseimbangan kelas, jumlah sampel, dan validasi eksternal merupakan prioritas penelitian lanjutan.

Kata kunci: Analisis Tingkat Kesalahan; CNN; *Error Level Analysis*; Forensik Citra Digital; Manipulasi Gambar.

1. LATAR BELAKANG

Perkembangan kamera digital, telepon pintar, dan perangkat lunak pengolah citra membuat pembuatan serta penyebaran gambar menjadi semakin mudah. Pada saat yang sama, perubahan isi gambar dapat dilakukan melalui berbagai teknik seperti copy-move, splicing, dan penghapusan objek. Literatur mutakhir menempatkan deteksi manipulasi gambar sebagai bagian penting dari forensik digital karena tujuan utamanya adalah membedakan citra autentik dari citra yang telah mengalami perubahan serta, pada beberapa pendekatan, melokalisasi area yang dimanipulasi (Zanardelli et al., 2023; Zare Mehrjardi et al., 2023). Perkembangan *Deep*

Learning juga mendorong penggunaan CNN dan arsitektur berbasis attention untuk mempelajari jejak forensik secara otomatis.

Salah satu pendekatan yang dapat digunakan sebagai representasi awal adalah *Error Level Analysis* (ELA). ELA memanfaatkan perbedaan kesalahan setelah citra dikompresi ulang sehingga bagian citra dengan karakteristik kompresi yang berbeda dapat lebih mudah diamati. Penelitian yang menggabungkan ELA dengan CNN melaporkan bahwa ELA dapat membantu proses deteksi splicing, sedangkan penelitian lain menggunakan informasi ELA bersama *Deep Learning* untuk mendeteksi manipulasi pada citra dokumen (Irmawati, 2023; [penelitian IEEE tentang ELA dan *Deep Learning*], 2022). Dengan demikian, ELA dapat ditempatkan sebagai tahap preprocessing/representasi, sedangkan CNN berperan dalam klasifikasi.

Penelitian terdahulu menunjukkan bahwa performa deteksi manipulasi sangat dipengaruhi oleh dataset dan karakteristik manipulasi. Pendekatan modern seperti D-Net mempertahankan informasi fingerprint forensik dan konteks global untuk mendeteksi splicing, sedangkan LBRT menggabungkan pemodelan konteks global dan penyempurnaan informasi lokal untuk copy-move forgery (Yang et al., 2024; Liang et al., 2024). Penelitian lain juga mengeksplorasi pembelajaran kontrasif, arsitektur multi-skala, serta jaringan ringan untuk meningkatkan kemampuan deteksi dan generalisasi (Zhang et al., 2023; Liang et al., 2023).

Berdasarkan kondisi tersebut, penelitian ini menggunakan foto dokumentasi SD Padedewatu sebagai sumber data lokal dan membentuk manipulasi terkontrol agar tersedia label asli dan manipulasi. Kebaruan penelitian terletak pada penerapan alur ELA-CNN pada koleksi foto lokal dengan pembagian data berdasarkan sumber foto untuk mengurangi kebocoran data. Tujuan penelitian adalah menganalisis hasil ELA, menguji kemampuan awal CNN dalam klasifikasi citra asli dan manipulasi, serta mengidentifikasi keterbatasan model berdasarkan *Accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*.

2. KAJIAN TEORITIS

Manipulasi Gambar dan Forensik Citra

Manipulasi gambar adalah proses mengubah sebagian atau seluruh isi citra sehingga informasi visual tidak lagi sama dengan sumber awal. Copy-move memindahkan salinan suatu bagian citra ke lokasi lain dalam citra yang sama, sedangkan splicing menggabungkan bagian dari citra lain ke dalam citra target. Penghapusan objek atau inpainting menghilangkan bagian tertentu dan mengisi area tersebut menggunakan informasi dari lingkungan citra. Survei mengenai deteksi pemalsuan menunjukkan bahwa copy-move dan splicing merupakan dua

kategori yang banyak diteliti dalam image forgery detection (Zanardelli et al., 2023; Zare Mehrjardi et al., 2023).

Error Level Analysis

ELA merupakan teknik yang memvisualisasikan perbedaan antara citra awal dan citra yang dikompresi ulang pada kualitas JPEG tertentu. Perbedaan tersebut dapat memberikan indikasi bahwa sebagian wilayah citra memiliki karakteristik kompresi yang berbeda. Penelitian ELA-CNN pada splicing menunjukkan bahwa ELA dapat digunakan sebagai informasi tambahan untuk klasifikasi, tetapi hasil ELA tetap dipengaruhi oleh riwayat kompresi dan karakteristik gambar sehingga tidak seharusnya diperlakukan sebagai bukti tunggal manipulasi (Irmawati, 2023).

Convolutional Neural Network

CNN merupakan arsitektur *Deep Learning* yang mempelajari pola spasial melalui operasi konvolusi. Dalam penelitian ini CNN digunakan sebagai classifier biner dengan kelas asli dan manipulasi. Penggunaan CNN untuk image forgery detection telah banyak dilaporkan, termasuk pada copy-move dan splicing. Penelitian DenseNet-201 untuk copy-move dan splicing menunjukkan potensi *Deep Learning* untuk klasifikasi citra forgery, sementara penelitian lain mengembangkan model ringan untuk lingkungan komputasi terbatas (Hidayat et al., 2023; Nguyen & Huynh, 2023).

Evaluasi Kinerja

Accuracy dihitung sebagai proporsi seluruh prediksi benar. *Precision* mengukur proporsi prediksi manipulasi yang benar-benar manipulasi, *recall* mengukur kemampuan menemukan citra manipulasi, sedangkan *F1-score* merupakan rata-rata harmonik *precision* dan *recall*. *Confusion matrix* digunakan untuk memperlihatkan distribusi prediksi pada setiap kelas. Penggunaan beberapa metrik penting karena *Accuracy* dapat memberikan gambaran yang kurang lengkap ketika distribusi kelas tidak seimbang.

3. METODE PENELITIAN

Sumber dan Komposisi Dataset

Data penelitian berasal dari 34 foto yang diberikan sebagai koleksi dokumentasi SD Padedewatu. Seluruh foto awal diperlakukan sebagai citra asli. Karena data awal tidak disertai label manipulasi, dibuat tiga jenis manipulasi terkontrol dari setiap foto sumber, yaitu copy-move, splicing, dan erasure. Setiap sumber menghasilkan tiga citra manipulasi sehingga diperoleh 34 citra asli dan 102 citra manipulasi. Total dataset adalah 136 citra.

Tabel 1. Komposisi dataset penelitian.

Kelas	Jumlah	Keterangan
Asli	34	Foto dokumentasi sumber
Copy-move	34	Bagian citra disalin dan ditempatkan pada lokasi lain
Splicing	34	Bagian dari foto lain ditempel pada citra target
Erasure	34	Area objek dihapus/disamarkan secara terkontrol
Total	136	34 asli + 102 manipulasi

Tahapan Penelitian



Gambar 1. Alur penelitian.

Tahapan penelitian terdiri atas pengumpulan foto, preprocessing, pembentukan representasi ELA, pembentukan dataset manipulasi terkontrol, pelatihan CNN, pengujian, dan evaluasi. Citra dikonversi ke RGB dan disiapkan untuk proses ELA. Pada tahap ELA, citra disimpan ulang dalam format JPEG pada kualitas tertentu, kemudian selisih antara citra awal dan hasil kompresi dihitung dan diskalakan untuk menghasilkan citra ELA.

Pembagian Data

Pembagian data dilakukan berdasarkan kelompok sumber foto, bukan secara acak pada seluruh citra turunan. Foto sekolah_01 sampai sekolah_24 beserta seluruh variasi manipulasinya digunakan sebagai data pelatihan, sedangkan sekolah_25 sampai sekolah_34 beserta variasinya digunakan sebagai data pengujian. Dengan strategi tersebut, variasi manipulasi yang berasal dari satu foto sumber tidak masuk ke kedua subset. Data pelatihan terdiri atas 96 citra dan data pengujian 40 citra.

Arsitektur dan Parameter CNN

CNN yang digunakan merupakan CNN sederhana dengan beberapa blok konvolusi untuk mengekstraksi pola dari citra ELA, kemudian adaptive average pooling dan lapisan klasifikasi dua kelas. Optimizer yang digunakan adalah Adam dengan learning rate 0,001 dan batch size 32. Pelatihan dilakukan selama 6 epoch sesuai eksperimen yang menghasilkan hasil evaluasi pada penelitian ini. Model digunakan untuk klasifikasi biner asli dan manipulasi.

Skenario Pengujian

Pengujian dilakukan terhadap 40 citra, terdiri atas 10 citra asli dan 30 citra manipulasi. Kinerja model diukur menggunakan *Accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Karena manipulasi dibuat secara terkontrol dari sumber foto yang sama, hasil pengujian ditafsirkan sebagai eksperimen awal dan bukan sebagai validasi terhadap seluruh jenis manipulasi nyata.

4. HASIL DAN PEMBAHASAN

Hasil *Error Level Analysis*


Gambar 2 memperlihatkan tiga foto sumber yang berbeda beserta representasi ELA masing-masing. Penggunaan tiga sumber berbeda dimaksudkan untuk memperlihatkan bahwa hasil ELA dapat berubah sesuai tekstur, detail objek, pencahayaan, dan riwayat kompresi foto. Pada penelitian ini ELA digunakan sebagai representasi tambahan sebelum klasifikasi, bukan sebagai keputusan final apakah sebuah foto pasti manipulatif. Hal tersebut penting karena artefak kompresi dapat muncul pada citra asli maupun citra manipulasi.



Gambar 2. Tiga Citra Berbeda dan Representasi *Error Level Analysis* (ELA)

Hasil Pelatihan CNN

Akurasi training meningkat dari 28,13% pada epoch pertama menjadi 54,17% pada epoch ketiga, kemudian berfluktuasi pada epoch berikutnya. Akurasi testing mencapai 75% mulai epoch ketiga dan bertahan hingga epoch keenam. Pola tersebut menunjukkan bahwa model mampu mempelajari pola tertentu dari representasi ELA, tetapi kestabilan pembelajaran belum dapat dianggap tinggi karena dataset relatif kecil.




Gambar 3. Perkembangan akurasi model CNN.

Evaluasi Model

Tabel 2. Hasil evaluasi model CNN pada data pengujian

Metrik	Hasil
Accuracy	75,00%
Precision	75,00%
Recall	100,00%
F1-Score	85,71%



Gambar 4. Confusion matrix model CNN.

Confusion matrix memperlihatkan bahwa dari 10 citra asli pada data pengujian, tidak ada yang diprediksi sebagai asli dan seluruhnya diprediksi sebagai manipulasi. Sementara itu, seluruh 30 citra manipulasi berhasil diprediksi sebagai manipulasi. Kondisi ini menghasilkan recall kelas manipulasi sebesar 100%, tetapi kemampuan model mengenali kelas asli sangat rendah. Dengan demikian, *Accuracy* 75% terutama muncul karena model berhasil mengklasifikasikan kelas manipulasi, bukan karena kedua kelas dikenali secara seimbang.

Pembahasan

Hasil penelitian menunjukkan bahwa integrasi ELA dan CNN dapat digunakan sebagai alur eksperimen untuk data lokal, tetapi hasil model pada dataset ini masih menunjukkan bias kelas. Temuan tersebut konsisten dengan perhatian dalam literatur bahwa performa image forgery detection sangat bergantung pada kualitas dataset, jenis manipulasi, dan kemampuan model mempertahankan fingerprint forensik (Zanardelli et al., 2023; Zare Mehrjardi et al., 2023). Penelitian ELA-CNN sebelumnya juga menunjukkan bahwa ELA dapat membantu klasifikasi splicing, tetapi peningkatan performa tetap bergantung pada dataset dan skenario pengujian (Irmawati, 2023).

Penelitian mutakhir mengembangkan pendekatan yang lebih kompleks. D-Net, misalnya, mempertahankan informasi fingerprint melalui dua encoder dan menggunakan perspektif global untuk deteksi splicing (Yang et al., 2024). LBRT menggunakan Transformer dengan cabang global dan lokal untuk mempertahankan detail manipulasi pada copy-move forgery (Liang et al., 2024). Penelitian lain menggunakan feature enhancement dan supervised contrastive learning untuk meningkatkan separabilitas kelas pada splicing forgery (Liang et al., 2023). Perkembangan tersebut menunjukkan bahwa CNN sederhana seperti yang digunakan pada penelitian ini lebih tepat ditempatkan sebagai baseline awal daripada model final untuk sistem forensik yang kompleks.

Keterbatasan utama penelitian adalah jumlah sumber foto asli yang hanya 34, distribusi dataset 34 asli berbanding 102 manipulasi, serta manipulasi yang dibuat secara terkontrol. Selain itu, tidak terdapat dataset eksternal yang digunakan untuk menguji generalisasi. Karena itu, hasil 75% tidak boleh dibandingkan langsung dengan akurasi tinggi yang dilaporkan penelitian pada dataset benchmark berukuran jauh lebih besar. Penelitian lanjutan perlu menambah sumber foto, menyeimbangkan kelas, memperbanyak variasi kompresi dan manipulasi, serta melakukan pengujian pada dataset eksternal. Pendekatan transfer learning atau arsitektur modern juga dapat dibandingkan dengan CNN baseline.

5. KESIMPULAN DAN SARAN

Penelitian ini menganalisis penerapan *Error Level Analysis* dan *Convolutional Neural Network* untuk deteksi awal manipulasi gambar menggunakan foto SD Padedewatu. Sebanyak 34 foto asli digunakan sebagai sumber dataset dan dibuat 102 variasi manipulasi terkontrol yang terdiri atas copy-move, splicing, dan erasure, sehingga total data berlabel berjumlah 136 citra. Pembagian berdasarkan sumber foto menghasilkan 96 citra pelatihan dan 40 citra pengujian. Model CNN menghasilkan *Accuracy* 75%, *precision* 75%, *recall* 100%, dan *F1-score* 85,71%. Namun, *confusion matrix* menunjukkan bahwa seluruh citra pengujian diprediksi sebagai manipulasi, termasuk citra asli. Oleh karena itu, model belum menunjukkan kemampuan klasifikasi dua kelas yang seimbang dan hasil penelitian harus dipandang sebagai eksperimen awal. Pengembangan selanjutnya disarankan menggunakan dataset yang lebih besar dan seimbang, manipulasi yang lebih realistis, validasi eksternal, serta perbandingan CNN dengan transfer learning atau arsitektur modern seperti Transformer.

DAFTAR REFERENSI

- Alam, S., & ... (2025). Recent advances in image forgery detection: Handcrafted feature extraction and deep learning-based approaches. *2025 International Conference on Electronics, AI and Computing (EAIC)*. <https://doi.org/10.1109/EAIC66483.2025.11101671>
- Anonymous authors. (2022). Document image forgery detection based on deep learning models. *2022 International Symposium on Electrical, Electronics and Information Engineering*. <https://doi.org/10.1109/ISEEIE55684.2022.00014>
- Anonymous authors. (2023). An approach for copy-move and image splicing forgery detection using automated deep learning. *2023 International Conference on Emerging Smart Computing and Informatics*. <https://doi.org/10.1109/ESCI56872.2023.10100202>
- Anonymous authors. (2025a). Detection of copy-move forgery with deep CNN features using machine learning classifier. *Procedia Computer Science*, 258, 3062–3071. <https://doi.org/10.1016/j.procs.2025.04.564>

- Anonymous authors. (2025b). Lightweight spatial attention pyramid network-based image forgery detection optimized for real-time edge TPU deployment. *Computers & Electrical Engineering*, 128, 110645. <https://doi.org/10.1016/j.compeleceng.2025.110645>
- Djaksana, Y. M., Rivai, A. K., & Supriyadi, D. (2022). Analisis manipulasi citra (image forgery) menggunakan integrasi metode Error Level Analysis dan Block Matching. *Jurnal ESIT*, 12(1).
- Fridrich, J., Soukal, D., & Lukáš, J. (2003). Detection of copy-move forgery in digital images. *Proceedings of Digital Forensic Research Workshop*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Irmawati, I. (2023). Image splicing forgery detection using Error Level Analysis and CNN. *Ultima InfoSys: Jurnal Ilmu Sistem Informasi*, 14(2), 79–86. <https://doi.org/10.31937/si.v14i2.3439>
- Liang, E., Zhang, K., Hua, Z., & Jia, X. (2025). Frequency-driven deep learning network for image splicing forgery detection. *Knowledge-Based Systems*, 114365. <https://doi.org/10.1016/j.knosys.2025.114365>
- Liang, P., Li, Z., Tu, H., & Zhao, H. (2024). LBRT: Local-information-refined Transformer for image copy-move forgery detection. *Sensors*, 24(13), 4143. <https://doi.org/10.3390/s24134143>
- Liang, Y., et al. (2023). Feature enhancement and supervised contrastive learning for image splicing forgery detection. *Digital Signal Processing*, 136, 104005. <https://doi.org/10.1016/j.dsp.2023.104005>
- Nguyen, H. L., & Huynh, K. T. (2023). A deep learning model for splicing image detection. *REV Journal on Electronics and Communications*, 13(3–4). <https://doi.org/10.21553/rev-jec.335>
- Nguyen, T. T., Nguyen, Q. V. H., Nguyen, D. T., Nguyen, D. T., Huynh-The, T., Nahavandi, S., Nguyen, T. T., Pham, Q.-V., & Nguyen, C. M. (2022). Deep learning for deepfakes creation and detection: A survey. *Computer Vision and Image Understanding*, 223, 103525. <https://doi.org/10.1016/j.cviu.2022.103525>
- Yang, Z., Liu, B., Bi, X., Xiao, B., Li, W., Wang, G., & Gao, X. (2024). D-Net: A dual-encoder network for image splicing forgery detection and localization. *Pattern Recognition*, 155, 110727. <https://doi.org/10.1016/j.patcog.2024.110727>
- Zanardelli, M., Guerrini, F., Leonardi, R., & Adami, N. (2023). Image forgery detection: A survey of recent deep-learning approaches. *Multimedia Tools and Applications*, 82, 17521–17566. <https://doi.org/10.1007/s11042-022-13797-w>
- Zare Mehrjardi, F., Latif, A. M., Sardari Zarchi, M., & Sheikhpour, R. (2023). A survey on deep learning-based image forgery detection. *Pattern Recognition*, 144, 109778. <https://doi.org/10.1016/j.patcog.2023.109778>
- Zhang, J., Wang, H., & He, P. (2023). Dual-branch multi-scale densely connected network for image splicing detection and localization. *Signal Processing: Image Communication*, 119, 117045. <https://doi.org/10.1016/j.image.2023.117045>

- Zhang, Y., et al. (2023). The Circular U-Net with Attention Gate for image splicing forgery detection. *Electronics*, 12(6), 1451. <https://doi.org/10.3390/electronics12061451>
- Zhou, et al. (2022). Learning to localize image forgery using end-to-end attention network. *Neurocomputing*, 512, 25–39. <https://doi.org/10.1016/j.neucom.2022.09.060>