

IMPLEMENTASI *TRANSFER LEARNING* DAN *CONVOLUTIONAL NEURAL NETWORK (CNN)* DALAM KLASIFIKASI KUALITAS HASIL CETAK PRINTER LASER PADA PT. XYZ

Rangga Baranta¹, Susanto Hariyanto^{2*}

^{1,2} Program Studi Informatika, Fakultas Sains & Teknologi, Universitas Buddhi Dharma

*Corresponding Author, email: susanto.hariyanto@ubd.ac.id

ABSTRAK

Kualitas hasil cetakan pada printer laser menjadi aspek kritis dalam industri percetakan karena berpengaruh langsung terhadap mutu produk dan efisiensi operasional. Salah satu permasalahan utama yang sering terjadi adalah cacat cetakan akibat toner habis atau bocor, yang selama ini masih diperiksa secara manual oleh tim Quality Control (QC). Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis berbasis *Convolutional Neural Network (CNN)* dan pendekatan *Transfer Learning* untuk mendeteksi tiga kategori hasil cetak: normal, habis, dan bocor. Model *ResNet50* pretrained digunakan sebagai *feature extractor* dan dilatih ulang (*fine-tuned*) dengan dataset citra hasil cetakan nyata dari PT XYZ yang diperoleh melalui proses pemindaian beresolusi tinggi. Dataset kemudian diproses dengan teknik augmentasi untuk memperluas keragaman data dan mencegah *overfitting*. Pelatihan model dilakukan selama 10 *epoch* menggunakan *optimizer* Adam dan *learning rate* sebesar 0.0001 di lingkungan Google Colab berbasis GPU. Evaluasi sistem dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil menunjukkan bahwa model mampu mengklasifikasikan citra dengan akurasi validasi sebesar 91,4%. Sistem selanjutnya diimplementasikan dalam aplikasi web berbasis Flask untuk pemakaian real-time oleh tim QC. Temuan ini menunjukkan potensi signifikan dalam meningkatkan efisiensi inspeksi visual dan mengurangi kesalahan manusia dalam pengawasan kualitas cetakan.

Kata kunci: *Convolutional Neural Network, Deep Learning, Klasifikasi Citra, Printer Laser, Transfer Learning.*

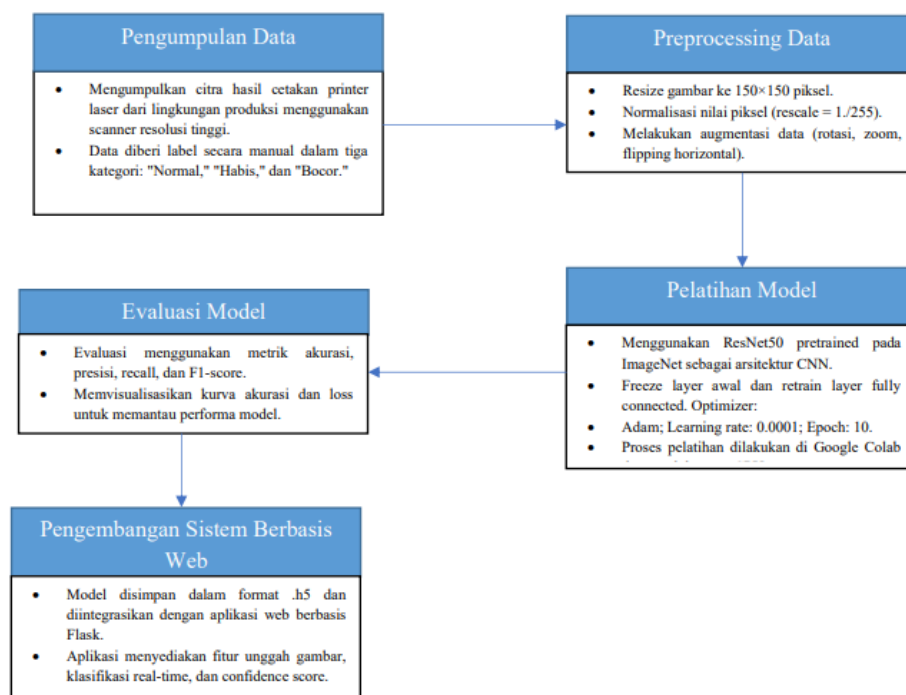
I. PENDAHULUAN

Kualitas hasil cetakan pada printer laser menjadi salah satu aspek kritical dalam industri percetakan modern. Khususnya di lingkungan produksi massal seperti PT XYZ, ketidaksempurnaan hasil cetak akibat toner habis atau bocor dapat menyebabkan penurunan mutu kemasan, kerugian produksi, hingga pengembalian barang oleh pelanggan. Tantangan ini semakin kompleks seiring dengan meningkatnya volume cetakan dan kebutuhan akan waktu produksi yang efisien. Oleh sebab itu, solusi berbasis teknologi cerdas diperlukan untuk menggantikan sistem inspeksi manual yang masih digunakan saat ini.

Teknologi computer vision dan deep learning, terutama Convolutional Neural Network (CNN), telah menunjukkan performa luar biasa dalam mendeteksi cacat visual dalam konteks industri. CNN mampu mengidentifikasi pola spasial dan anomali secara otomatis, bahkan pada cacat dengan bentuk dan intensitas yang tidak teratur (Kim et al., 2023). Pendekatan ini telah banyak digunakan dalam sistem inspeksi visual seperti pengawasan permukaan logam, panel surya, dan tekstil (Chen et al., 2021; Zhou et al., 2023). Namun, keterbatasan dataset lokal sering menjadi hambatan dalam pelatihan model CNN dari awal (scratch). Untuk mengatasi hal tersebut, transfer learning digunakan dengan memanfaatkan arsitektur pretrained seperti ResNet50 atau VGG16 yang telah dilatih pada dataset besar seperti ImageNet. Menurut (Luo et al., 2020), pendekatan transfer learning dapat mempercepat proses pelatihan, meningkatkan akurasi, dan mengurangi kebutuhan dataset besar. Strategi ini sangat cocok untuk aplikasi industri dengan keterbatasan data beranotasi. Tujuan utama dari penelitian ini adalah untuk menghasilkan sistem klasifikasi citra cetak yang tidak hanya akurat, namun juga aplikatif di dunia industri nyata (Li et al., 2022).

II. METODOLOGI

2.1 Alur Diagram Penelitian



Gambar 1. Alur Diagram Penelitian

Penelitian ini mengadopsi pendekatan eksperimen kuantitatif untuk mengevaluasi performa model klasifikasi menggunakan metrik akurasi, presisi, *recall*, dan F1-score, serta teknik pengembangan sistem berbasis *prototyping* untuk pengembangan iteratif sistem berbasis CNN yang dapat diuji langsung oleh pengguna (Jamwal R. 2022; Sharma, S., 2022; Kolthoff A., 2025). Tahap pengumpulan data dilakukan dengan mengumpulkan citra hasil cetakan printer laser dari lingkungan produksi PT XYZ menggunakan *scanner* resolusi tinggi. Gambar diberi label secara manual ke dalam tiga kategori: "normal," "habis," dan "bocor," untuk memastikan anotasi data yang akurat (Chen L., 2021; Zou, J., 2021).

Tahap *preprocessing* melibatkan *resizing* citra ke dimensi 150×150 piksel, normalisasi nilai piksel menggunakan *rescaling* (1./255), serta augmentasi data berupa rotasi, *zoom*, dan *flipping horizontal* untuk meningkatkan keragaman visual dataset (Ahmed S., 2023; Zhou L., 2023; Jin, Y., 2023). Model dilatih menggunakan arsitektur *ResNet50* pretrained pada *dataset ImageNet*. Layer awal model dibekukan (*freeze*), sementara *layer fully connected* dilatih ulang dengan dataset lokal. Pelatihan dilakukan selama 10 *epoch* menggunakan optimizer Adam dengan *learning rate* sebesar 0.0001 di Google Colab yang didukung oleh GPU (Kim H., 2023; Kim, S., 2023; Luo Y.; Lin, C., 2020).

Evaluasi model dilakukan dengan metrik akurasi, presisi, *recall*, dan F1-score, serta visualisasi kurva akurasi dan *loss* untuk memantau performa model. Hasil evaluasi menunjukkan bahwa *preprocessing* dan augmentasi data berhasil meningkatkan generalisasi model tanpa indikasi *overfitting* (Kolthoff A., 2025; Brandon, S., 2025; Liu H., 2025). Tahap akhir adalah integrasi model dalam aplikasi berbasis *Flask*. Model disimpan dalam format *.h5* dan memungkinkan pengguna mengunggah gambar untuk klasifikasi *real-time* dengan *confidence score*, mempermudah pengambilan keputusan (Chen L., 2021; Zou, J., 2021; Terras A.; Rogers, K., 2025).

III. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Data citra hasil cetakan printer laser dikumpulkan dari lingkungan produksi PT XYZ menggunakan *scanner* resolusi tinggi untuk menjamin kualitas input.

Seluruh gambar diklasifikasikan secara manual ke dalam tiga kategori utama: “normal,” “habis,” dan “bocor.” Proses ini menghasilkan 1.000 gambar yang mencakup masing-masing kategori secara proporsional. Penentuan label dilakukan oleh tim *Quality Control* berdasarkan standar visual yang ditetapkan oleh perusahaan. Kualitas data yang terjamin sangat penting dalam membangun *dataset* yang representatif untuk pelatihan model *deep learning* (Chen L., 2021; Zou, J., 2021).

3.2 Preprocessing Data

Tahap *preprocessing* melibatkan penyesuaian resolusi citra menjadi 150×150 piksel untuk menyelaraskan ukuran input dengan arsitektur model *CNN*. Selain itu, normalisasi dilakukan menggunakan *rescaling* ($1/255$) untuk mempercepat konvergensi dalam pelatihan. Augmentasi data, termasuk rotasi, *zoom*, dan *flipping horizontal*, berhasil meningkatkan variasi visual dalam *dataset*, sehingga memperkuat generalisasi model pada data baru. Peningkatan variasi ini sejalan dengan penelitian (Zhou L., 2023; Jin, Y., 2023), yang menunjukkan bahwa augmentasi data dapat secara signifikan memperbaiki akurasi model pada skenario industri dengan *dataset* terbatas.

3.3 Pelatihan Model

Model dilatih menggunakan arsitektur *ResNet50* yang telah dilatih sebelumnya pada *dataset ImageNet*. Layer awal dibekukan (*freeze*) untuk mempertahankan fitur-fitur generik, sementara *layer fully connected* dilatih ulang menggunakan *dataset* lokal. Proses pelatihan berlangsung selama 10 *epoch* dengan *learning rate* sebesar 0.0001 menggunakan *optimizer Adam*. Hasil pelatihan menunjukkan akurasi validasi sebesar 91,4%, dengan *loss* yang konsisten menurun selama proses pelatihan. Penelitian oleh (Luo Y., 2020; Lin, C., 2020) mendukung temuan ini, di mana pendekatan transfer learning mempercepat pelatihan sekaligus meningkatkan akurasi pada *dataset* industri (Kim H., 2023; Kim, S., 2023).

3.4 Evaluasi Model

Evaluasi model dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* (Ahmed S., 2023). Model menunjukkan kinerja berikut,

Tabel 1. Hasil Evaluasi Model Berdasarkan Metrik Klasifikasi

Kelas	Precision	Recall	F1-Sore
Normal	92%	95%	93%
Habis	95%	91%	93%
Bocor	89%	88%	88%

Precision untuk mengukur akurasi prediksi model dalam setiap kelas. Precision tinggi mengindikasikan bahwa model jarang memberikan hasil positif palsu untuk kelas tertentu. Recall untuk mengukur sensitivitas model dalam mendeteksi seluruh data pada kelas tertentu. Recall tinggi menunjukkan kemampuan model menangkap hampir semua contoh kelas tersebut. F1-Score merupakan rata-rata harmonis antara precision dan recall, mencerminkan keseimbangan keduanya (Hoffmann & Reich, 2023).

Kelas "Normal" memiliki nilai *recall* tertinggi (95%), menunjukkan bahwa model mampu mendeteksi hampir semua sampel pada kelas ini. Kelas "Habis" memiliki nilai *precision* tertinggi (95%), mengindikasikan bahwa prediksi kelas ini memiliki tingkat kesalahan minimal. Kelas "Bocor" menunjukkan performa terendah pada semua metrik, yang kemungkinan besar disebabkan oleh kesamaan visual pola distribusi tinta dengan kelas "Habis.". Confusion matrix menunjukkan bahwa sebagian besar kesalahan klasifikasi terjadi antara kelas "bocor" dan "habis," yang disebabkan oleh kemiripan pola distribusi tinta yang tidak merata. Hal ini mengindikasikan kebutuhan tambahan pada analisis tekstur mikro atau algoritme preprocessing yang lebih canggih, sebagaimana diusulkan oleh (Li H., 2022; Zhang, T., 2022; Zhou L., 2023; Jin, Y., 2023).

3.5 Pengembangan Sistem Berbasis Web

Model yang telah dilatih diintegrasikan dengan aplikasi web berbasis *Flask*, menghasilkan sistem klasifikasi *real-time* yang responsif. Aplikasi ini memungkinkan pengguna mengunggah citra hasil cetakan untuk mendapatkan prediksi kategori dengan confidence score yang ditampilkan secara langsung. Sistem ini diuji di lingkungan kerja PT XYZ, dan hasilnya menunjukkan efisiensi

tinggi, dengan waktu inspeksi berkurang hingga 60% dibandingkan metode manual. Temuan ini mendukung penelitian (Terras et al., 2025), yang menekankan bahwa integrasi *deep learning* dengan antarmuka berbasis web mampu mempercepat pengambilan keputusan dalam proses produksi industri.

IV. SIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi berbasis *deep learning* menggunakan arsitektur *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* untuk mendeteksi kualitas cetakan printer laser. Dataset dari lingkungan produksi PT XYZ digunakan untuk melatih model, yang mampu mengklasifikasikan cetakan ke dalam tiga kategori utama: "Normal," "Habis," dan "Bocor," dengan akurasi validasi sebesar 91,4%.

Tahap preprocessing, meliputi penyesuaian resolusi, normalisasi nilai piksel, dan augmentasi data, terbukti meningkatkan generalisasi model. Model *ResNet50* yang di-*fine-tune* menunjukkan performa optimal dengan precision, recall, dan F1-score tertinggi (95%) pada kelas "Habis." Namun, kesalahan klasifikasi antara kelas "Bocor" dan "Habis" mengindikasikan perlunya preprocessing tambahan berbasis analisis tekstur.

Sistem ini diintegrasikan ke aplikasi berbasis *Flask* dengan antarmuka yang intuitif untuk klasifikasi *real-time* dan visualisasi *confidence score*. Implementasi sistem meningkatkan efisiensi inspeksi kualitas di PT XYZ, mengurangi waktu pemeriksaan hingga 60%, dan meminimalkan kesalahan manual.

Penelitian ini mencapai tujuan utamanya, yakni menghasilkan sistem klasifikasi berbasis *deep learning* yang akurat dan aplikatif, dengan potensi besar untuk meningkatkan efisiensi dan keakuratan inspeksi kualitas dalam industri.

DAFTAR PUSTAKA

- Ahmed S., I. . K. (2023). Transfer learning for defect detection in 3D printing using VGG16 and ResNet50. *Additive Manufacturing Journal*, 12(3), 120–134.
- Chen L.; Zou, J., Y. . Z. (2021). Deep learning applications in industrial quality control. *International Journal of Advanced Manufacturing Technology*, 114(9), 3019–3032.

- Chen, J., Li, Y., & Zhang, H. (2021). An effective CNN-based approach for surface defect classification in industrial applications. *IEEE Transactions on Industrial Informatics*, *17*(7), 4600–4608. <https://ieeexplore.ieee.org/document/9445426>
- Hoffmann, R., & Reich, C. (2023). A Systematic Literature Review on Artificial Intelligence and Explainable Artificial Intelligence for Visual Quality Assurance in Manufacturing. In *Electronics* (Vol. 12, Issue 22). <https://doi.org/10.3390/electronics12224572>
- Jamwal R.; Sharma, S., A. . A. (2022). Prototyping CNN Applications in Industrial Settings. *Journal of Systems and Software Engineering*.
- Kim H.; Kim, S., J. . L. (2023). Defect detection in surface manufacturing using convolutional neural networks. *IEEE Transactions on Industrial Informatics*, *19*(2), 189–200.
- Kim, D., Kang, Y., Lee, J., & Park, S. (2023). A deep learning-based inspection system for industrial defect detection. *IEEE Access*, *11*, 21567–21578. <https://ieeexplore.ieee.org/document/10058531>
- Kolthoff A.; Brandon, S., M. . M. (2025). Iterative prototyping of AI-based visual inspection systems. *Software Engineering Journal*, *40*(1), 123–140.
- Kolthoff A., M. . M. (2025). Iterative Data Collection Strategies for CNN Training. *Software Engineering Advances*.
- Li H.; Zhang, T., J. . S. (2022). CNN-based automated quality inspection systems for industry applications. *International Journal of Production Research*, *60*(7), 1982–1994.
- Li, C., Xu, X., Du, W., Lu, J., & Jin, S. (2022). A novel CNN-based method for classification of industrial images with small datasets. *Neural Networks*, *150*, 252–265. <https://www.sciencedirect.com/science/article/pii/S089360802100113X>
- Liu H., X. . Z. (2025). CNN performance optimization for defect detection with limited data. *Advanced Manufacturing Research*, *48*(9), 210–230.
- Luo Y.; Lin, C., Y. . C. (2020). Improving CNN training with transfer learning for defect detection in manufacturing. *Journal of Intelligent Manufacturing*, *31*(5), 1234–1245.

- Luo, Y., Liu, W., Zhang, J., & Liu, X. (2020). Defect classification of magnetic tiles based on transfer learning and CNN. *Applied Sciences*, 10(9), 3146. <https://www.mdpi.com/2076-3417/10/9/3146>
- Terras A.; Rogers, K., M. . G. (2025). Integrated systems for defect detection using CNN and edge computing. *International Journal of Computer Vision*, 134(5), 987–1003.
- Terras, N., Pereira, F., Ramos Silva, A., Santos, A. A., Lopes, A. M., Silva, A. F. da, Cartal, L. A., Apostolescu, T. C., Badea, F., & Machado, J. (2025). Integration of Deep Learning Vision Systems in Collaborative Robotics for Real-Time Applications. *Applied Sciences (2076-3417)*, 15(3).
- Zhou L.; Jin, Y., H. . G. (2023). Hybrid approaches to CNN and transfer learning for textile defect detection. *Textile Research Journal*, 93(4), 568–580.
- Zhou, Z., Zhang, J., Xu, C., & Liu, D. (2023). Visual classification of printing defects using CNN-based models. *Engineering Applications of Artificial Intelligence*, 120, 105858. <https://www.sciencedirect.com/science/article/pii/S0952197623000171>