

AUTOMATED VISUAL INSPECTION PADA PRODUK CASTING MANUFACTURING MENGGUNAKAN DEEP CONVOLUTIONAL NEURAL NETWORK

Imaduddin Ariefa^{1*}, Sendie Yulianto Margen¹, Della Kumalaningrum¹, Komar Roni¹, Hawa Rizka²

¹ Jurusan Teknik Mesin, Politeknik Negeri Semarang

Jl. Prof. Soedarto, Tembalang, Kec. Tembalang, Kota Semarang, Jawa Tengah 50275

² Jurusan Teknik Mesin, Politeknik Negeri Jakarta

Jl. Prof. DR. G.A. Siwabessy, Kukusan, Kecamatan Beji, Kota Depok, Jawa Barat 16425

*Email: imaduddin.ariefa@polines.ac.id

Abstrak

Untuk mencegah faktor subjektivitas dan potensi human error saat pengecekan kualitas produk casting manufacturing secara manual, penelitian ini bertujuan mengembangkan sistem Automated Visual Inspection (AVI) berbasis AI. Metode yang digunakan dengan pendekatan Deep learning berbasis Convolutional Neural Network (CNN) dengan membandingkan kinerja antara arsitektur AlexNet dan Development architecture. Proses evaluasi menggunakan 6.633 citra riil hasil preprocessing yang terbagi atas kelas defect dan non-defect untuk data training dan validasi. Hasil eksperimen membuktikan keunggulan architecture AlexNet yang mencatatkan akurasi hingga 99,25% dengan validation loss sebesar 0,02481, sementara architecture pengembangan hanya menghasilkan tingkat akurasi 89,07%. Hasil analisis confusion matrix juga memperlihatkan tingkat kestabilan AlexNet yang sangat tinggi dengan nilai presisi, recall, serta F1-score melebihi 0,99. Kesimpulan dari penelitian ini menegaskan bahwa architecture AlexNet memiliki efektivitas yang jauh lebih tinggi dalam mendeteksi cacat pada komponen pengecoran logam, menjadikannya opsi yang sangat relevan untuk diaplikasikan dalam sistem kendali mutu otomatis di industri.

Kata kunci: *Automated Visual Inspection; Deep learning; Convolutional Neural Network; AlexNet; Casting Manufacturing*

PENDAHULUAN

Industri pengecoran logam (*casting manufacturing*) berperan penting dalam sektor-sektor strategis seperti otomotif, kedirgantaraan, dan permesinan. Kualitas produk cor sangat penting bagi integritas struktural, keandalan, dan kinerja komponen yang dihasilkan. Namun, proses manufaktur pengecoran seringkali memiliki banyak kekurangan, seperti porositas, inklusi, cacat permukaan (*slag*), dan retakan (*cracks*). Jika cacat ini tidak terdeteksi dengan tepat, dapat menyebabkan kegagalan produk dan meningkatkan biaya produksi akibat pengerjaan ulang dan *scrap* (Park et al., 2022).

Banyak industri saat ini masih bergantung pada metode pemeriksaan visual manual, di mana manusia memeriksa setiap produk secara langsung dengan melakukan pengecekan satu per satu. Metode ini memiliki kelemahan antara lain subjektivitas dalam pengambilan keputusan, kelelahan fisik dan mental yang menurunkan konsentrasi operator, serta rentan terhadap kesalahan manusia (Yu et al., 2021). Keterbatasan ini mengakibatkan inkonsistensi dalam pengendalian kualitas, khususnya pada skala produksi volume tinggi.

Automated Visual Inspection (AVI) telah muncul sebagai solusi potensial untuk mengatasi keterbatasan inspeksi manual. Kemajuan terbaru dalam *Deep Learning*, khususnya *Convolutional Neural Network* (CNN), telah mengubah kapasitas sistem untuk pemrosesan gambar. CNN dapat secara otomatis mempelajari dan mengekstrak fitur hierarkis kompleks dari data gambar, yang membuatnya lebih baik dalam mengklasifikasikan dan mendeteksi objek (He et al., 2016). Sejumlah penelitian telah menunjukkan bahwa CNN efektif dalam mendeteksi cacat pada berbagai material, termasuk permukaan logam (H. Shi et al., 2022).

Tetapi, banyak penelitian yang sering kali dilakukan dalam lingkungan yang terkontrol, menggunakan *dataset* dengan variasi cacat, sudut pengambilan gambar, dan kondisi pencahayaan yang terbatas (Fei et al., 2022). Hal ini menciptakan kesenjangan antara kemampuan model untuk bekerja dalam lingkungan akademis dan tantangan dunia nyata di rantai produksi. Dalam dunia

industri nyata, terdapat banyak sekali jenis cacat, sehingga sistem harus dapat menemukannya dengan cepat dan akurat.

Dari permasalahan di atas, penelitian ini fokus pada penerapan *deep convolutional neural network* untuk membangun sistem AVI yang dapat mengatasi tantangan nyata di industri. Kebaruan penelitian ini terletak pada penerapan dan evaluasi model yang memanfaatkan kumpulan data industri pengecoran dunia nyata yang merangkum kompleksitas tersebut, yang berfungsi sebagai langkah strategis menuju industrialisasi pengendalian kualitas berbasis AI.


Kajian teoritik yang mendasari penelitian ini meliputi bidang Computer Vision dan *deep learning*. Computer Vision menyediakan dasar untuk memahami bagaimana informasi diekstrak dari gambar digital. Sementara itu, *deep learning*, khususnya CNN, merupakan state-of-the-art dalam pemrosesan gambar. *Architecture CNN AlexNet* dan *manually designed architecture* telah terbukti efektif dalam berbagai tugas visi komputer berkat kemampuannya menangkap fitur spasial yang kompleks melalui lapisan konvolusionalnya (He et al., 2016; Tan & Le, 2020). Beberapa penelitian pendahuluan telah berhasil mengaplikasikan CNN untuk inspeksi permukaan baja, tekstil, dan semikonduktor (Fei et al., 2022; R. Shi et al., 2023).

METODE

Penelitian ini mengimplementasikan *deep learning* untuk melakukan inspeksi visual pada produk pengecoran dengan memanfaatkan data gambar. Metode yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (CNN). Pendekatan serupa dalam pemanfaatan data gambar dan optimalisasi jaringan konvolusional untuk komponen manufaktur logam juga terus dikembangkan dalam studi-studi mutakhir (Wei et al., 2024; Wu et al., 2025; Yousef et al., 2026). Dalam pelaksanaannya, data yang dikumpulkan dibagi menjadi dua kategori utama: cacat (*defect*) dan non-cacat (*non-defect*). Dengan menggunakan CNN, sistem dapat dilatih untuk mengenali pola-pola visual pada gambar produk pengecoran yang menunjukkan adanya cacat atau kerusakan, seperti retakan, pori-pori, atau kekurangan lainnya. CNN dapat mengekstrak fitur-fitur penting dari gambar dan secara akurat mengklasifikasikannya sebagai produk sempurna atau cacat. Metode ini mempunyai banyak potensi untuk membuat pemeriksaan produk pengecoran menjadi lebih efisien, menurunkan angka human error, dan mempercepat penemuan cacat pada proses produksi. Implementasi *deep learning* dengan CNN ini tidak hanya memungkinkan analisis citra secara otomatis, tetapi juga memberikan solusi yang lebih cepat dan lebih akurat dibandingkan metode inspeksi visual konvensional.

Dataset


Dataset citra casting yang digunakan dalam studi ini terdiri dari total 3758 citra yang diberi label sebagai cacat casting dan 2875 citra yang diberi label sebagai non-cacat casting. Semua gambar berformat RGB dan berukuran 227 x 227 piksel. Gambar 1 menunjukkan tampilan *dataset* yang akan digunakan untuk melatih CNN.



Gambar 1. (a) defect casting (b) non-defect casting

Preprocessing

Untuk mencegah overfitting selama *training* data, CNN memerlukan jumlah data gambar yang sangat besar. *Preprocessing* adalah teknik yang digunakan untuk memperbanyak kumpulan data *training* dengan berbagai metode transformasi, pada Gambar 2 merupakan proses pre-processing gambar hingga masuk ke *training* model CNN. Pada penelitian ini, tahap *preprocessing* mencakup beberapa proses penting resize dan rotasi gambar.



Gambar 2. *Pre-processing of input images to the CNN network, feature extraction, and classification.*

Split Data

Proses pemisahan data dalam pelatihan CNN bertujuan untuk membagi *dataset* menjadi beberapa bagian agar model dapat dilatih, divalidasi, dan diuji secara efektif. Dalam penelitian ini, proporsi data yang digunakan untuk pelatihan adalah 80%, sementara 20% sisanya digunakan untuk validasi, berdasarkan total 8704 gambar yang tersedia. Tabel 1 menunjukkan pembagian data antara pelatihan dan validasi yang digunakan dalam model CNN yang diusulkan dalam penelitian ini.

Tabel 1. *Data splitting in proposed CNN*

Factors	Data splitting percentage	Total number of images after data Preprocessing
Train	80%	6963
Validation	20%	1741
Total	100%	8704


Architecture CNN

CNN adalah jenis jaringan saraf tiruan yang dibuat khusus untuk bekerja dengan data seperti grid, seperti gambar. *Architecture* CNN terdiri dari beberapa lapisan yang bekerja sama untuk mengekstrak fitur penting dari input data, memprosesnya, dan menghasilkan output yang diinginkan.

AlexNet

Ada lima lapisan konvolusional dalam *architecture AlexNet*, diikuti oleh tiga lapisan yang terhubung sepenuhnya. *AlexNet* menggunakan kernel besar, seperti 11x11 pada lapisan pertama dan 5x5 pada lapisan berikutnya, di lapisan konvolusional. Hal ini memungkinkan model mengekstrak fitur yang lebih kompleks. Setiap lapisan konvolusi diikuti oleh lapisan pooling yang membantu mengurangi dimensi spasial peta fitur, sehingga mengurangi jumlah parameter dalam model. *AlexNet* juga menggunakan ReLU (Rectified Linear Unit) sebagai fungsi aktivasi untuk meningkatkan kinerja dan mempercepat pelatihan. Ini lebih cepat daripada fungsi aktivasi lain seperti sigmoid (Krizhevsky, 2012).

AlexNet juga menggunakan dropout pada lapisan yang terhubung sepenuhnya untuk mengurangi overfitting dengan mematikan beberapa neuron secara acak selama pelatihan. *Architecture* ini juga menggunakan teknik augmentasi data untuk menambah *dataset* dan meningkatkan kemampuan generalisasi model gambar 3, yang merupakan lapisan yang dimiliki oleh *architecture AlexNet*.



Gambar 3. *Architecture AlexNet*

HASIL DAN PEMBAHASAN

Parameter penelitian yang digunakan dalam penelitian ini digambarkan pada Tabel 2, sedangkan perangkat lunak yang digunakan untuk pelatihan model adalah MATLAB. Selain itu Tabel 2 menunjukkan hasil akurasi model terbaik dengan menggunakan *architecture AlexNet* sebesar 99,25% dan validation loss sebesar 0,02481. Nilai validation loss yang sangat kecil menunjukkan bahwa model ini tidak banyak melakukan kesalahan dalam penggunaan data validasi sehingga *architecture AlexNet* mampu melakukan generalisasi dengan sangat baik pada *dataset* yang digunakan.

Kemudian untuk *development architecture* nilai akurasinya rendah dan nilai validation lossnya tinggi. Ini menunjukkan bahwa pengembangan model belum seefektif *AlexNet* dalam mengenali pola data. Berdasarkan metrik evaluasi pada Tabel 3, *architecture AlexNet* memiliki presisi, perolehan, dan skor F1 semuanya di atas 0,99 yang berarti model sangat akurat, seimbang, dan stabil. Hasilnya sejalan dengan (Wang et al., 2021) yang mengatakan bahwa *AlexNet* sangat baik dalam mengklasifikasikan cacat permukaan pada bagian logam karena *architecture* stabil saat pencahayaan dan tekstur permukaan berubah.

Untuk *development architecture*, nilai metrik rata-rata berada di antara 0,88 dan 0,89 yang berarti model tersebut masih cukup baik tetapi belum memenuhi standar *AlexNet*. Masalah utamanya adalah nilai recall sebesar 0,88783 yang berarti model tersebut sering gagal mengenali objek positif (misalnya, gagal mendeteksi def front). Hal ini menunjukkan bahwa *architecture* tersebut belum optimal untuk mengekstraksi fitur atau menggeneralisasi data validasi.

Tabel 2. Parameter dan Hasil *Training* model CNN


No	<i>Architecture</i> model	Optimizer	Epoch	Learning rate	Validation loss	Validation accuracy (%)
1	<i>AlexNet</i>	SGDM	30	0.001	0,02481	99,25%
2	Development <i>Architecture</i>				0,3063	89,07%

Tabel 3. *Evaluation metrics*

No	Evaluasi Model	<i>AlexNet</i>	Development <i>Architecture</i>
1	Average Precision	0,99145	0,88934
2	Average Recall	0,99335	0,88783
3	Average F1-Score	0,99234	0,88854

Gambar 4 (a) *confussion matrix* menunjukkan seberapa baik model yang terlatih dapat memprediksi gambar untuk setiap kelas. Berdasarkan gambar 4 dan tabel 5, positif benar (TP = 742) berarti 742 gambar dengan kelas def_front diprediksi dengan benar sebagai def_front. Negatif Salah (FN = 10) berarti 10 gambar def_front salah diberi label sebagai ok_front. Positif salah (FP = 0) berarti tidak ada gambar ok_front yang salah diklasifikasikan sebagai def_front. Kemudian, Negatif Benar (TN = 575) berarti 575 gambar ok_front diklasifikasikan dengan benar. Nilai TP dan TN yang

tinggi berarti model dapat mengenali kedua kelas dengan sangat baik, sementara nilai FN dan FP yang sangat rendah berarti tingkat kesalahan prediksi model sangat rendah.



Gambar 4. Confussion matrix (a) AlexNet (b) Development Architecture


Tabel 5. Analisis Confusion matrix architecture AlexNet

Architecture	True Class	Predicted def front	Predicted ok front	Total Data
AlexNet	def_front	742 (TP)	10 (FN)	752
	ok_front	0 (FP)	575 (TN)	575
Development	def_front	684 (TP)	68 (FN)	752
	ok_front	77 (FP)	498 (TN)	575

Berdasarkan gambar 4 (b) dan tabel 5, nilai true positive (TP) untuk *development architecture* adalah 684, yang berarti gambar def_front (cacat) diklasifikasikan dengan benar. False negative (FN) 68, yang berarti gambar def_front salah diklasifikasikan sebagai ok_front (cacat tetapi tidak terdeteksi). False Positive (FP) adalah 77, yang berarti gambar ok_front salah diklasifikasikan sebagai def_front (produk tersebut diduga cacat). Yang terakhir True Negative (TN) sebesar 498, yang artinya gambar ok_front sudah terklasifikasi dengan benar. Skor akurasi sebesar 89,07% untuk *development architecture* menunjukkan bahwa ia bekerja cukup baik, tetapi masih jauh dari hasil AlexNet sebelumnya sebesar 99,25%. Hal ini karena model masih membuat kesalahan yang signifikan saat memvalidasi data, dengan 68 kasus def_front tidak terdeteksi (FN) dan 77 kasus ok_front salah diidentifikasi sebagai cacat (FP). Ini berarti model tersebut belum cukup stabil untuk membedakan antara fitur normal dan fitur yang rusak.

Setelah melakukan *training* model, langkah selanjutnya yaitu melakukan testing model dengan menggunakan data baru yang belum pernah dilakukan *training* sebelumnya. Data test yang digunakan yaitu sejumlah 715 gambar yang terbagi menjadi 453 gambar untuk kategori *defect* dan 262 gambar dengan kategori non *defect*. Model AlexNet pada tabel 6 menunjukkan hasil yang sangat baik dalam mengenali gambar dari kedua kelas. Berdasarkan prediksi, semua sampel di kelas de_front dan ok_front diklasifikasikan dengan benar dengan tingkat kepercayaan 99,5–100%. Hal ini menunjukkan bahwa *architecture AlexNet* dapat secara efektif mengekstrak fitur visual dari gambar masukan, baik itu mendeteksi tepian, tekstur, atau pola intensitas yang membedakan produk cacat dari produk tidak cacat. Keberhasilan ini juga menunjukkan bahwa AlexNet dapat menangani *dataset* industri yang memiliki karakteristik visual sederhana tetapi membutuhkan akurasi tinggi. Namun, akurasi yang sempurna ini juga dapat mengindikasikan adanya potensi overfitting, terutama jika jumlah data latihan yang digunakan relatif sedikit atau kurang bervariasi.

Tabel 6. Hasil prediksi pada sampel dari setiap kelas

AlexNet			Development Architecture		
True: defect Pred: defect (100.0%)	True: defect Pred: defect (100.0%)	True: defect Pred: defect (100.0%)	True: defect Pred: defect (99.9%)	True: defect Pred: defect (99.9%)	True: defect Pred: defect (94.0%)
					
True: okront Pred: okront (100.0%)	True: okront Pred: okront (99.9%)	True: okront Pred: okront (100.0%)	True: okront Pred: okront (71.2%)	True: okront Pred: okront (93.9%)	True: okront Pred: okront (54.1%)
					

KESIMPULAN

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan bahwa pengembangan sistem *Automated Visual Inspection* (AVI) berbasis *Deep learning* dengan metode CNN terbukti sangat efektif dan andal dalam mendeteksi serta mengklasifikasikan cacat pada produk pengecoran logam (*casting manufacturing*). Implementasi *architecture AlexNet* menunjukkan performa yang jauh lebih unggul dengan akurasi sebesar 99,25% dan tingkat validation loss yang sangat rendah yaitu sebesar 0,02481, lebih unggul dibandingkan dengan model *architecture* pengembangan (*Development architecture*) yang hanya memiliki akurasi 89,07%. Keunggulan ini juga diperkuat oleh kestabilan nilai presisi, recall, dan F1-score yang konsisten di atas 0,99 berdasarkan analisis *confusion matrix*. Dengan demikian, sistem otomatisasi berbasis *architecture AlexNet* ini berhasil menjawab tantangan penelitian dengan memberikan solusi inspeksi visual yang objektif, konsisten, dan minim risiko human error, sehingga sangat layak dan siap untuk diimplementasikan pada lini kendali mutu industri pengecoran logam skala besar.

DAFTAR PUSTAKA

- Fei, Z., Yang, E., Yu, L., Li, X., Zhou, H., & Zhou, W. (2022). A Novel deep neural network-based emotion analysis system for automatic detection of mild cognitive impairment in the elderly. *Neurocomputing*, 468, 306–316. <https://doi.org/10.1016/j.neucom.2021.10.038>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Krizhevsky, A. , S. I. , & H. G. E. (2012). *ImageNet classification with deep Convolutional Neural Networks*.
- Park, S.-H., Lee, K.-H., Park, J.-S., & Shin, Y.-S. (2022). Deep Learning-Based Defect Detection for Sustainable Smart Manufacturing. *Sustainability*, 14(5), 2697. <https://doi.org/10.3390/su14052697>
- Shi, H., Ouyang, Q., Wang, X., Yang, Y., Song, T., Hao, J., & Huang, X. (2022). Insight into the formation of conjugated ladder structure of polyacrylonitrile by X-ray photoelectron spectroscopy. *Measurement*, 200, 111565. <https://doi.org/10.1016/j.measurement.2022.111565>
- Shi, R., Yu, X., Chen, H., Jiao, Y., Chen, J., Chen, F., & He, S. (2023). Research on the behaviour and mechanism of void welding based on multiple scales. *High Temperature Materials and Processes*, 42(1). <https://doi.org/10.1515/htmp-2022-0271>
- Tan, M., & Le, Q. V. (2020). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*.

- Wang, Y., Guo, Z., Bai, X., & Yuan, C. (2021). Effect of weld defects on the mechanical properties of stainless-steel weldments on large cruise ship. *Ocean Engineering*, 235, 109385. <https://doi.org/10.1016/j.oceaneng.2021.109385>
- Wei, L., Solihin, M. I., Saruchi, S., Atifah, Astuti, W., Hong, L. W., & Kit, A. C. (2024). Surface Defects Detection of Cylindrical High-Precision Industrial Parts Based on *Deep Learning Algorithms*: A Review. *Operations Research Forum*, 5(3), 58. <https://doi.org/10.1007/s43069-024-00337-5>
- Wu, L., Ran, Y., Yan, L., Liu, Y., Song, Y., & Han, D. (2025). A *Dataset* for surface defect detection on complex structured parts based on photometric stereo. *Scientific Data*, 12(1), 276. <https://doi.org/10.1038/s41597-025-04454-6>
- Yousef, N., Parmar, C., Sata, A., & Edacherian, A. (2026). Quantum neural networks for casting defect detection: a hybrid intelligence framework for smart manufacturing. *Quantum Information Processing*, 25(3), 89. <https://doi.org/10.1007/s11128-026-05113-4>
- Yu, Q., Yang, H., Lin, K.-Y., & Li, L. (2021). A self-organized approach for scheduling semiconductor manufacturing systems. *Journal of Intelligent Manufacturing*, 32(3), 689–706. <https://doi.org/10.1007/s10845-020-01678-8>