



Deteksi Defect Sepatu Berbasis Fine-Tuned CNN Menggunakan Arsitektur DenseNet untuk Mendukung Proses Quality Control

Jamila¹, Eka Legya Frannita^{1,*}, Gilang Fatikhul Burhan¹, Nunik Purwaningsih¹, Windra Bangun Nuswantoro¹, Anwar Hidayat¹, Erlita Pramitaningrum¹, Totok Yulaidin², Alifia Revan Prananda³

¹ Program Studi Teknologi Pengolahan Produk Kulit, Politeknik ATK Yogyakarta, Yogyakarta, Indonesia

² Program Studi Manajemen, Universitas Bina Sehat PPNI, Mojokerto, Indonesia

³ Program Studi Teknologi Informasi, Universitas Tidar, Magelang, Indonesia

Email: ¹jamila@politeknikatk.ac.id, ^{2,*}eka.legya@atk.ac.id, ³gilangfb@politeknikatk.ac.id, ⁴nunik@politeknikatk.ac.id,

⁵windrnb@atk.ac.id, ⁶anwar@atk.ac.id, ⁷erlita.pramitaningrum@politeknikatk.ac.id, ⁸xojexblack@gmail.com, ⁹revan@untidar.ac.id

Email Penulis Korespondensi: eka.legya@politeknikatk.ac.id

Abstrak—Indonesia merupakan salah satu negara dengan angka ekspor sepatu yang cukup banyak dan menduduki peringkat ketiga setelah Cina dan India. Walaupun menjadi salah satu top tier exporting alas kaki, proses produksi alas kaki di Indonesia masih mengalami berbagai kendala yang sering kali menghambat proses produksi. Salah satu permasalahan penting adalah proses quality control atau QC yang masih dilakukan secara manual. Penelitian ini mengusulkan pengembangan model shoes defect detection berbasis artificial intelligence untuk meningkatkan akurasi dan efisiensi proses QC. Penelitian ini menggunakan dataset primer yang diperoleh dari Laboratorium PID 4.0 Politeknik ATK Yogyakarta dan diuji dalam empat skenario eksperimen yang berbeda. Jumlah data terdiri dari 2.828 citra yang dibagi menjadi dua kelas (kelas good dan kelas reject). Metode yang digunakan dalam penelitian ini adalah fine-tuned CNN dengan arsitektur DenseNet dengan proporsi pembagian jumlah data untuk training, validation dan testing sebesar 80:10:10. Berdasarkan hasil eksperimen, penggunaan augmentasi data dan adam optimizer menghasilkan performa tertinggi akurasi, precision, recall dan F1-score sebesar 0.9546, 0.9551, 0.9546, dan 0.9545. Hasil tersebut menunjukkan bahwa penerapan model deep learning berpotensi mengurangi tingkat reject dengan memodernisasi metode QC tradisional, sehingga dapat meningkatkan daya saing industri alas kaki Indonesia di pasar global.

Kata Kunci: Defect Detection; DenseNet; Footwear; Quality Control

Abstract—Indonesia is a leading global exporter of footwear. Despite successfully exports million pair of shoes, shoes industry in Indonesia faces significant challenges due to conventional quality control (QC) limitations. This study proposes a deep learning-based defect detection model to enhance the efficiency and accuracy of the QC process. This study uses primary datasets collected from Laboratory of PID 4.0 Politeknik ATK Yogyakarta and employed in four experimental scenarios. The dataset consists of 2,828 images comprising of two classes (good class and reject class). This study utilizes fine-tuned CNN using DenseNet architecture for distinguishing two classes. Before employing the fine-tuned CNN method, we separate the data into three components, which are training, validation and testing data, with proportion of 80:10:10. The results demonstrate that the integration of data augmentation and the Adam optimizer yielded the highest performance, achieving accuracy, precision, recall and F1-score of 0.9546, 0.9551, 0.9546, 0.9545, respectively. These findings suggest that implementing automated deep learning models has potential to reduce rejection rates by modernizing traditional inspection methods, which can strengthen the competitiveness of Indonesia's footwear industry in the global market.

Keywords: Defect Detection; DenseNet; Footwear; Quality Control

1. PENDAHULUAN

Indonesia menjadi salah satu kontributor utama dalam perdagangan global produk alas kaki. Berdasarkan data yang disampaikan oleh Asosiasi World Footwear melalui World Footwear Yearbook Report pada tahun 2024, Indonesia menempati peringkat ketiga secara internasional dalam ekspor sepatu, dengan volume mencapai 601 juta pasang per tahun (World Footwear, 2024). Pencapaian tersebut mencerminkan posisi strategis industri alas kaki nasional dalam rantai nilai global serta kontribusinya terhadap pertumbuhan ekonomi dan ekspor non-migas (Suhartini & Ramadhan, 2021). Keberadaan banyak perusahaan penanaman modal asing (PMA) yang bergerak di sektor manufaktur alas kaki di Indonesia menunjukkan besarnya potensi pengembangan industri ini, baik dari sisi investasi, penyerapan tenaga kerja, maupun peningkatan kapasitas teknologi produksi (Nurhayani et al., 2023)(Cesarriani, 2025).

Proses produksi alas kaki merupakan rangkaian kegiatan yang kompleks dan multi-tahap (Bondar et al., 2024), mulai dari persiapan dan pemilihan bahan baku, pemotongan material, penjahitan, perakitan, hingga tahap finishing (Rossi et al., 2021)(Nareswari et al., 2023). Setiap tahapan produksi memiliki karakteristik teknik dan parameter kualitas yang berbeda, sehingga manajemen mutu dan QC menjadi aspek penting untuk memastikan produk akhir memenuhi standar yang ditetapkan (Su et al., 2025)(Laksanawati et al., 2024)(Ratnayake & Ratnayake, 2023). Namun, praktik QC pada industri alas kaki saat ini masih sangat bergantung pada inspeksi manual oleh tenaga manusia. Inspeksi manual tersebut dilakukan secara bertahap pada setiap proses untuk meminimalisir kemungkinan cacat (defect) produk. Meski demikian, ketergantungan pada pemeriksaan visual dan penilaian subjektif menyebabkan proses QC menjadi sangat memakan waktu, rentan terhadap kesalahan manusia, dan sulit distandarisasi (Vong et al., 2021).

Kondisi ini berdampak pada tingginya jumlah cacat yang masih ditemukan pada produk akhir (end-product), meskipun telah dilakukan pemeriksaan di berbagai tahap. Berdasarkan penelitian yang dilakukan oleh Suhartini dkk, dari total produksi 87.498 pasang sepatu terdapat 2.454 pasang sepatu dengan kondisi reject dengan rata-rata jumlah reject sebanyak lebih dari 80 pasang per hari (Suhartini & Ramadhan, 2021). Penelitian serupa dilakukan oleh Nurhayani dkk melaporkan dari 285.000 pasang sepatu yang diproduksi terdapat 11.496 pasang sepatu dengan kondisi

reject (Nurhayani et al., 2023). Hal ini menunjukkan bahwa proses QC konvensional belum mampu menjamin konsistensi mutu yang tinggi dan efisiensi produksi yang optimal, terutama pada volume produksi yang besar dan variasi produk yang meningkat.

Di sisi lain, pemanfaatan AI memiliki potensi besar untuk mengotomasi dan meningkatkan kualitas proses inspeksi di berbagai bidang (Bettoni et al., 2025)(Niu et al., 2025)(Pérez-Calabuig et al., 2025)(Mustafa et al., 2026)(Yiting et al., 2026). Beberapa studi di industri alas kaki telah mulai mengeksplorasi otomasi inspeksi kualitas produk. Seperti penelitian yang diusulkan oleh Jaebong dkk. Penelitian tersebut mengusulkan penerapan CNN-based object detection untuk inspeksi permukaan alas kaki. Penelitian tersebut berhasil mengembangkan sistem deteksi cacat permukaan sepatu menggunakan deep learning untuk QC otomatis (Cho et al., 2025). Klarak dkk mengusulkan penggunaan sistem penginderaan visual (kamera & sensor laser) untuk inspeksi posisi bagian sepatu dalam proses produksi. Penelitian ini membahas fitur inspeksi visual *camera vision*, relevan sebagai dasar teknologi pemeriksaan otomatis di lini produksi sepatu (Klarák et al., 2021).


Berdasarkan penelitian terdahulu, sebagian besar studi mengenai *automated defect detection* berfokus pada pengembangan dan pengujian model AI pada dataset terbatas dan lingkungan laboratorium yang terkontrol. Penelitian-penelitian tersebut umumnya menitikberatkan pada peningkatan akurasi algoritma, perbandingan arsitektur model, atau optimasi parameter, tanpa mempertimbangkan aspek integrasi sistem secara menyeluruh pada lini produksi nyata. Akibatnya, luaran penelitian lebih bersifat prototipe algoritmik jangka pendek dan belum siap untuk langsung diimplementasikan pada skala industri. Selain itu, sebagian besar penelitian belum mengakomodasi kompleksitas industri alas kaki yang melibatkan variasi desain, material, serta tahapan produksi yang beragam. Pendekatan yang ada umumnya hanya berfokus pada inspeksi produk akhir (*end-product inspection*) dan belum mengembangkan sistem inspeksi multi-tahap yang terintegrasi secara real-time dalam alur produksi.

Melihat peluang pemanfaatan AI dalam proses QC pada beberapa penelitian terdahulu, pengembangan system QC berbasis AI untuk produksi alas kaki juga memiliki potensi pengembangan yang besar. Sistem QC otomatis berbasis data-driven AI dapat melakukan inspeksi secara konsisten, cepat, dan objektif terhadap variasi cacat permukaan maupun cacat struktural produk alas kaki. Berdasarkan permasalahan tersebut, penelitian ini mengusulkan pengembangan model fine-tuned CNN untuk mendeteksi defect pada sepatu sebagai bagian dari proses *quality control* pada industri alas kaki.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Permasalahan dalam proses QC atau inspeksi sepatu masih sering mengurangi produktivitas yang menyebabkan tingginya tingkat produk cacat (reject). Untuk mengatasi hal tersebut, pendekatan deep learning berbasis Convolutional Neural Network (CNN) yang mampu mengekstraksi fitur visual secara otomatis dari citra sepatu diusulkan dalam penelitian sebagai alternatif solusi untuk meningkatkan akurasi dan efisiensi proses QC. Proses penelitian yang diusulkan dimulai dengan tahapan pengumpulan dan pelabelan data citra sepatu (baik untuk kelas good maupun reject), dilanjutkan dengan tahap preprocessing (data cleaning), feature engineering dan pelatihan model untuk mempelajari pola cacat, kemudian dilakukan pengujian guna mengevaluasi kinerja model menggunakan metrik seperti akurasi, presisi, dan recall. Hasil dari model berupa klasifikasi kondisi sepatu serta potensi deteksi area cacat diharapkan dapat menggantikan atau mendukung inspeksi manual, sehingga meningkatkan efisiensi, konsistensi, dan kualitas kontrol dalam industri alas kaki. Gambar 1 mengilustrasikan kerangka berfikir dari penelitian yang diusulkan.




Gambar 1. Kerangka berfikir

Gambar 1 menunjukkan alur proses metode yang digunakan dimulai dari tahap data cleaning untuk membersihkan data seperti data yang tidak valid. Setelah itu dilakukan feature engineering untuk mengekstraksi fitur penting yang digunakan dalam proses pelatihan model. Proses ini dilakukan oleh arsitektur CNN yang digunakan. Training data digunakan bersama learning algorithm untuk membangun model pada tahap train model. Dalam proses tersebut juga ada data validation yang digunakan untuk mengevaluasi hasil training pada setiap epoch. New data pada

diagram ini merupakan data testing yang digunakan untuk menguji performa model melalui score model. Tahap akhir adalah evaluate model untuk mengevaluasi akurasi, recall, dan precision dari model yang telah dikembangkan.

2.2 Tahapan Penelitian

Penelitian ini merupakan penelitian kualitatif berbasis eksperimen. Penelitian ini terdiri dari beberapa tahapan yakni tahap pengumpulan data, tahap pra-pemrosesan data, tahap splitting data, tahap pengembangan arsitektur deep learning, tahap pelatihan model deep learning, tahap validasi, tahap pengujian dan tahap analisis. Alur penelitian diilustrasikan pada Gambar 2.



Gambar 2. Alur penelitian

Gambar 2 menunjukkan alur penelitian yang dimulai dari pengumpulan data. Data diambil dengan menggunakan kamera ultra-HD 4K dengan jarak dan pencahayaan yang cukup. Dalam proses pengambilan data, beberapa expert dilibatkan guna untuk menentukan dan mevalidasi ground truth. Langkah selanjutnya adalah pra-pemrosesan data. Pada tahap ini, dilakukan data cleaning proses yang bertujuan untuk memastikan data sesuai dengan kebutuhan arsitektur deep learning yang digunakan. Setelah data yang dikumpulkan siap, langkah selanjutnya yakni pengembangan model deep learning, pelatihan model dan pengujian model. Dalam tahap ini dilakukan eksperimen dengan empat skenario berbeda. Hasil kemudian dianalisis dan dibandingkan untuk mendapatkan skenario dengan performa terbaik.

2.2.1 Pengumpulan Data

Penelitian ini menggunakan dataset primer dalam bentuk citra digital sepatu yang diambil dari laboratorium Satelit PIDI 4.0 Politeknik ATK Yogyakarta. Adapun deskripsi detail data yang digunakan terdapat pada Tabel 1.

Tabel 1. Deskripsi dataset

Komponen	Deskripsi
Tipe data	Shoes defect images (patch)
Ukuran data	224 x 224 piksel
Ground truth	Klasifikasi dengan dua kelas yakni kelas <i>reject</i> dan kelas <i>good</i>
Proporsi data	Jumlah data 2.828 citra dengan rincian: a. kelas reject sebanyak 1344 citra b. kelas good sebanyak 1484 citra
Sumber data	Laboratorium Satelit PIDI 4.0 Politeknik ATK Yogyakarta

Tabel 1 menjelaskan spesifikasi dataset yang digunakan mulai dari ukuran citra, ground truth, jumlah data, jumlah kelas, proporsi data pada setiap kelas dan sumber data atau lokasi pengambilan data. Contoh dataset yang digunakan diilustrasikan pada Gambar 3.



(a)



(b)

Gambar 3. Contoh dataset: (a) kelas good dan (b) kelas reject

Pada Gambar 3, gambar 3(a) menunjukkan kondisi baik (kelas good) yang ditandai dengan kondisi bersih tanpa ada bagian yang tidak rapi. Sedangkan pada Gambar 3(b), terdapat defect dalam bentuk outsole berwarna hitam yang tidak rata pada bagian ujung sepatu atau yang ditunjukkan oleh tanda panah kuning. Kondisi ini disebut kelas reject.


2.2.2 Pengembangan Arsitektur DenseNet

Penelitian ini menggunakan metode fine-tuned CNN dengan arsitektur DenseNet. Metode ini dipilih karena sangat efektif untuk kasus klasifikasi dengan dataset kompleks. Metode untuk juga memiliki keunggulan seperti memperkecil kemungkinan overfitting (Nugroho & Frannita, 2021). Penggunaan arsitektur DenseNet merujuk pada keterbatasan arsitektur CNN tradisional seperti VGG dan ResNet yakni proses pembelajaran fitur yang redundan serta masalah *vanishing gradient*. DenseNet terdiri dari 121 lapisan, yang disusun menggunakan dense block dan transition layer, serta memiliki sekitar 8 juta parameter, jauh lebih sedikit dibandingkan dengan VGG16 (sekitar 138 juta parameter) dan ResNet50 (sekitar 25,6 juta parameter) tetapi memiliki performa yang sangat baik (Frannita & Prananda, 2026). Adapun arsitektur DenseNet yang digunakan diilustrasikan pada Tabel 2.

Tabel 2. Arsitektur DenseNet

Layer	Operasi	Output Shape
Input layer	Input Image	$224 \times 224 \times 3$
Initial convolution	Conv 7×7 , 64 filters, stride 2	$112 \times 112 \times 64$
Max pooling	Pool 3×3 , stride 2	$56 \times 56 \times 64$
Dense block 1	Dense connections (6 layers)	$56 \times 56 \times 256$
Transition layer 1	Conv 1×1 + Avg Pool 2×2	$28 \times 28 \times 128$
Dense block 2	Dense connections (12 layers)	$28 \times 28 \times 512$
Transition layer 2	Conv 1×1 + Avg Pool 2×2	$14 \times 14 \times 256$
Dense block 3	Dense connections (24 layers)	$14 \times 14 \times 1024$
Transition layer 3	Conv 1×1 + Avg Pool 2×2	$7 \times 7 \times 512$
Dense block 4	Dense connections (16 layers)	$7 \times 7 \times 1024$
Global average pooling	Feature aggregation	$1 \times 1 \times 1024$
Fully connected layer	Dense + Activation (Sigmoid/Softmax)	1×2 (2 kelas)

Tabel 2 menunjukkan komponen atau layer yang ada pada arsitektur DenseNet. Dalam tabel tersebut terdapat beberapa komponen beserta dengan function atau operasi, parameter standar, ukuran, hingga output. Berdasarkan Tabel 2, DenseNet yang digunakan dalam penelitian ini terdiri convolution layer, max pooling, dense block, transition layer, global average pooling dan fully connected layer. Pengaturan parameter dalam penelitian ini, terutama pada bagian output shape, disesuaikan dengan kondisi kasus seperti jumlah kelas, color space citra dan parameter lainnya.



Gambar 4. Arsitektur CNN

Dalam proses pelatihan model, terdapat empat skenario yang dilakukan. Hal ini bertujuan untuk mencari set-up atau parameter yang paling sesuai dengan kasus sehingga dapat menghasilkan akurasi terbaik. Skenario yang diterapkan dalam penelitian ini dideskripsikan pada Tabel 3.

Tabel 3. Set-up parameter untuk setiap skenario

Skenario	Augmentation	Dense value	Dropout value	Optimizer
1	Without augmentation	512	0.3	Adam
2	Without augmentation	512	0.3	SGD
3	With augmentation	512	0.3	Adam
4	With augmentation	512	0.3	SGD

Setiap skenario di atas, dilatih dengan menggunakan ukuran citra 224×224 , batch size 16 dan jumlah epoch sebanyak 45 epoch. Sebelum proses training dimulai, data dibagi menjadi tiga proporsi yakni data training, data validation dan data testing dengan persentase 80:10:10. Untuk metode data augmentation yang digunakan antara lain rotation (range: 40), horizontal flip, width shift (range: 0.2), height shift (range: 0.2), shear (range: 0.2), dan zoom (range: 0.2).


2.2.3 Pengujian Model Deep Learning

Proses pengujian dilakukan dengan mengevaluasi model. Proses ini melibatkan beberapa metrik evaluasi yang meliputi perhitungan akurasi pada proses training, validation dan testing. Selain itu juga dilakukan evaluasi pada loss yang dihasilkan pada proses training, validation dan testing.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Skenario 1

Penelitian ini bertujuan untuk mengembangkan model defect detection berbasis CNN dengan menggunakan arsitektur DenseNet. Pada tahap pelatihan model dilakukan proses pelatihan model dengan menerapkan empat scenario sebagaimana dijelaskan pada Tabel 3. Pada skenario 1, aturan yang diterapkan adalah tidak menggunakan data augmentation, menggunakan dense value sebesar 512, menggunakan dropout value sebesar 0.3, dan menggunakan Adam optimizer. Adapun hasil dari pelatihan model menggunakan skenario 1 dapat dilihat pada Gambar 5. Gambar tersebut menunjukkan hasil eksperimen menggunakan skenario 1 yang meliputi akurasi dan loss selama proses training dan validation serta confusion matrix untuk hasil testing. Hasil ini selanjutnya dibandingkan dengan hasil dari skenario lainnya untuk menentukan model mana yang memiliki performa yang paling baik untuk kasus defek sepatu.




Gambar 5. Hasil skenario 1: (a) grafik akurasi training dan validation, (b) grafik loss training dan validation, dan (c) hasil testing

Gambar 5(a) menunjukkan tren akurasi selama proses training dan validation. Gambar 5(b) menunjukkan tren loss selama proses training dan validation. Berdasarkan kedua gambar tersebut, hasil training menunjukkan tren yang cukup bagus dengan akurasi puncak yang stabil di angka 1 dan loss yang rendah. Namun, hasil validasi menunjukkan gap yang cukup tinggi. Hal ini menunjukkan bahwa variasi data cukup tinggi sehingga model belum bisa memprediksi dengan cukup baik. Gambar 5(c) merupakan confusion matrix untuk proses testing. Dari confusion matrix tersebut diperoleh akurasi, precision, recall dan F1-score sebesar 0.9311, 0.9314, 0.9311, dan 0.9309.

3.2 Hasil Skenario 2

Pada skenario 2, aturan yang diterapkan adalah tidak menggunakan data augmentation, menggunakan dense value sebesar 512, menggunakan dropout value sebesar 0.3, dan menggunakan SGD optimizer. Adapun hasil dari pelatihan model menggunakan skenario 2 dapat dilihat pada Gambar 6. Gambar tersebut menunjukkan hasil eksperimen menggunakan skenario 2 yang meliputi akurasi dan loss selama proses training dan validation serta confusion matrix untuk hasil testing. Hasil ini selanjutnya dibandingkan dengan hasil dari skenario lainnya untuk menentukan model mana yang memiliki performa yang paling baik untuk kasus defek sepatu.




Gambar 6. Hasil skenario 2: (a) grafik akurasi training dan validation, (b) grafik loss training dan validation, dan (c) hasil testing

Gambar 6(a) menunjukkan tren akurasi selama proses training dan validation. Gambar 6(b) menunjukkan tren loss selama proses training dan validation. Berdasarkan kedua gambar tersebut, hasil training menunjukkan tren yang

cukup bagus dengan akurasi puncak yang stabil diangka 1 dan loss yang rendah. Namun, hasil validasi menunjukkan gap yang cukup tinggi. Hal ini menunjukkan bahwa variasi data cukup tinggi sehingga model belum bisa memprediksi dengan cukup baik. Gambar 6(c) merupakan confusion matrix untuk proses testing. Dari confusion matrix tersebut diperoleh akurasi, precision, recall dan F1-score sebesar 0.9296, 0.9298, 0.9296, 0.9294. Berdasarkan hasil tersebut, skenario 1 dengan aturan tidak menggunakan data augmentation, menggunakan dense value sebesar 512, menggunakan dropout value sebesar 0.3, dan menggunakan Adam optimizer memiliki performa yang lebih baik dibandingkan dengan skenario 2. Kesimpulan dari kedua skenario ini adalah, dengan parameter yang sama Adam optimizer memiliki performa yang lebih baik dibandingkan dengan SGD optimizer.

3.3 Hasil Skenario 3

Pada skenario 3, aturan yang diterapkan adalah menggunakan data augmentation, menggunakan dense value sebesar 512, menggunakan dropout value sebesar 0.3, dan menggunakan Adam optimizer. Adapun hasil dari pelatihan model menggunakan skenario 3 dapat dilihat pada Gambar 7. Gambar tersebut menunjukkan hasil eksperimen menggunakan skenario 3 yang meliputi akurasi dan loss selama proses training dan validation serta confusion matrix untuk hasil testing. Hasil ini selanjutnya dibandingkan dengan hasil dari skenario lainnya untuk menentukan model mana yang memiliki performa yang paling baik untuk kasus defek sepatu.




Gambar 7. Hasil skenario 3: (a) grafik akurasi training dan validation, (b) grafik loss training dan validation, dan (c) hasil testing

Gambar 7(a) menunjukkan tren akurasi selama proses training dan validation. Gambar 7(b) menunjukkan tren loss selama proses training dan validation. Berdasarkan kedua gambar tersebut, hasil training menunjukkan tren yang cukup bagus dengan akurasi puncak yang stabil diangka 1 dan loss yang rendah. Berbeda dengan dua skenario sebelumnya, hasil validasi menunjukkan gap yang relatif rendah. Hal ini menunjukkan bahwa variasi data yang cukup tinggi dapat diprediksi dengan baik oleh model. Gambar 7(c) merupakan confusion matrix untuk proses testing. Dari confusion matrix tersebut diperoleh akurasi, precision, recall dan F1-score sebesar 0.9546, 0.9551, 0.9546, dan 0.9545. Berdasarkan hasil tersebut, skenario 3 memiliki performa yang lebih baik dibandingkan dengan skenario 1 dan 2 dengan aturan tidak menggunakan data augmentation, menggunakan dense value sebesar 512, menggunakan dropout value sebesar 0.3, dan menggunakan Adam dan SGD optimizer. Kesimpulan dari ketiga skenario ini adalah, dengan parameter yang sama Adam optimizer memiliki performa yang lebih baik dibandingkan dengan SGD optimizer, namun jika dikombinasikan dengan augmentasi data maka hasil dari Adam optimizer meningkat cukup signifikan.

3.4 Hasil Skenario 4

Pada skenario 4, aturan yang diterapkan adalah menggunakan data augmentation, menggunakan dense value sebesar 512, menggunakan dropout value sebesar 0.3, dan menggunakan SGD optimizer. Adapun hasil dari pelatihan model menggunakan skenario 4 dapat dilihat pada Gambar 8. Gambar tersebut menunjukkan hasil eksperimen menggunakan skenario 4 yang meliputi akurasi dan loss selama proses training dan validation serta confusion matrix untuk hasil testing.



Gambar 8. Hasil skenario 4: (a) grafik akurasi training dan validation, (b) grafik loss training dan validation, dan (c) hasil testing



Gambar 8(a) menunjukkan tren akurasi selama proses training dan validation. Gambar 8(b) menunjukkan tren loss selama proses training dan validation. Berdasarkan kedua gambar tersebut, hasil training menunjukkan tren yang cukup bagus dengan akurasi puncak yang stabil diangka 1 dan loss yang rendah. Namun, hasil validasi menunjukkan gap yang cukup tinggi. Hal ini menunjukkan bahwa variasi data cukup tinggi sehingga model belum bisa memprediksi dengan cukup baik. Gambar 8(c) merupakan confusion matrix untuk proses testing. Dari confusion matrix tersebut diperoleh akurasi, precision, recall dan F1-score sebesar 0.9139, 0.9138, 0.9139, dan 0.9138. Berdasarkan hasil tersebut, skenario 4 memiliki performa yang paling rendah dibandingkan dengan ketiga skenario sebelumnya. Kesimpulan dari keempat skenario ini adalah, Adam optimizer memiliki performa yang lebih baik dari SGD optimizer. Augmentasi data dapat berpengaruh pada setiap model, namun memiliki pengaruh yang berbeda. Pada Adam optimizer, augmentasi data dapat menaikkan performa dengan cukup signifikan. Sebaliknya, pada SGD optimizer proses augmentasi data tidak memberikan dampak positif.

3.4 Pembahasan

Berdasarkan hasil dari skenario 1 hingga skenario 4, rangkuman hasil keempat skenario diilustrasikan pada Tabel 4. Pada tabel tersebut, dideskripsikan seluruh hasil dari training hingga testing berdasarkan eksperimen yang telah dilakukan.

Tabel 4. Rekap hasil training, validation dan testing

Evaluasi	Komponen	Skenario			
		1	2	3	4
Training	Akurasi	1.0000	0.9960	0.9966	0.9555
	Loss	0.0002	0.0347	0.0137	0.1335
Validation	Akurasi	0.6339	0.6018	0.7757	0.5881
	Loss	1.1583	0.8113	0.5474	0.6817
	Akurasi	0.9311	0.9296	0.9546	0.9139
Testing	Loss	0.2253	0.1684	0.1518	0.1856
	Recall	0.9314	0.9297	0.9551	0.9138
	Precision	0.9311	0.9296	0.9546	0.9139
	F1-score	0.9309	0.9294	0.9545	0.9138

Berdasarkan hasil pada Tabel 4, dapat disimpulkan bahwa scenario 3 memiliki performa yang lebih baik dibandingkan dengan scenario yang lain. Hasil tersebut menunjukkan bahwa untuk kasus klasifikasi defect sepatu sneakers, proses augmentasi sangat mempengaruhi akurasi yang dihasilkan. Selain itu pemilihan Adam optimizer sebagai metode optimizer terlihat memberikan performa yang baik dibandingkan dengan SGD. Berdasarkan hasil tersebut dapat disimpulkan bahwa penggunaan data augmentasi secara signifikan meningkatkan akurasi testing sebesar kurang lebih 5% dibandingkan skenario awal. Hasil pada proses testing menunjukkan akurasi tertinggi sebesar 0.9546 dengan loss sebesar 0.1518, recall sebesar 0.9551, precision sebesar 0.9546 dan F1-score sebesar 0.9545. Hasil menunjukkan perbaikan dari penelitian sebelumnya yang dilakukan oleh Lam et.al [21] dengan akurasi sebesar 0.9180.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan model deep learning untuk mengklasifikasikan defect pada sepatu sneakers. Dataset yang digunakan dalam penelitian ini merupakan dataset primer yang dikumpulkan di laboratorium Satelit PIDI 4.0 Politeknik ATK Yogyakarta. Dataset yang digunakan sejumlah 2.828 citra yang terdistribusi dalam dua kelas (reject dan good). Dalam penelitian ini dilakukan empat eksperimen dengan set-up parameter yang berbeda untuk menentukan model deep learning yang paling sesuai dengan kasus. Berdasarkan hasil eksperimen, penggunaan data augmentation dan Adam optimizer memberikan performa terbaik dengan akurasi sebesar 0.9546. Untuk pengembangan penelitian selanjutnya, dapat dilakukan eksplorasi terhadap variasi arsitektur model yang lebih kompleks serta penggunaan dataset dengan jenis-jenis defek yang lebih kompleks agar reliabilitas model yang dikembangkan semakin baik.

REFERENCES

- Bettoni, A., Corti, D., Masiero, S., Barut, Z. M., Ejsmont, K., Gladysz, B., & Kosieradzka, A. (2025). AI-Enabled Quality Control in Manufacturing: Evidence from an Empirical Sample of SMEs. *IFAC-PapersOnLine*, 59(24), 203–208. <https://doi.org/https://doi.org/10.1016/j.ifacol.2025.11.865>
- Bondar, Oleksander, Chertenko, Liliia, Spahiu, Tatjana, & Shehi, Ermira. (2024). Shoe customization in a mass-production mode. *Journal of Engineered Fibers and Fabrics*, 19, 15589250241239248. <https://doi.org/10.1177/15589250241239247>
- Cesarriani, C. (2025). Analisis Kualitas untuk Mengurangi Defect Produk Sepatu dengan Metode Statistical Process Control dan Root Cause Analysis di PT XYZ. *Jurnal Logic : Logistics & Supply Chain Center*, 03(02), 78–86. <https://doi.org/https://doi.org/10.33197/jlsc.v3i2.2488>



- Cho, J., Nam, J., & Cho, H. (2025). Automated Footwear Surface Inspection System Based on the Deep Learning Object Detection. *Advances in Production Management Systems. Cyber-Physical-Human Production Systems: Human-AI Collaboration and Beyond.*, 1(769), 341–353. https://doi.org/10.1007/978-3-032-03550-9_23
- Frannita, E. L., & Prananda, A. R. (2026). Mobile app-based leather defects identification with fine-tuned CNNs. *Measurement*, 259, 119650. <https://doi.org/https://doi.org/10.1016/j.measurement.2025.119650>
- Klarák, J., Kuric, I., Zajačko, I., Bulej, V., Tlach, V., & Józwik, J. (2021). Analysis of Laser Sensors and Camera Vision in the Shoe Position Inspection System. In *Sensors* (Vol. 21, Issue 22, p. 7531). <https://doi.org/10.3390/s21227531>
- Laksanawati, E. K., Nindhia, T. G. T., & Susihono, W. (2024). Application of Lean Manufacturing in the Shoe Industry During the VUCA Era using VUCALEAN. *E3S Web of Conferences*, 576. <https://doi.org/10.1051/e3sconf/202457601002>
- Mustafa, G., Yao, Z., Wang, L., Zhao, S., Wang, H., Quan, H., Liu, J., Asad, M. A. U., Ali, M., & He, K. (2026). AI and spectroscopy synergy: Revolutionizing fungal infection detection in fresh fruits for enhanced quality control. *TrAC Trends in Analytical Chemistry*, 198, 118740. <https://doi.org/https://doi.org/10.1016/j.trac.2026.118740>
- Nareswari, C., Abdillah, I. T., Kurniawati, A., & Rizana, A. F. (2023). Design of E-Learning Content to Support Special Order Footwear Production. *2023 11th International Conference on Information and Education Technology (ICIET)*, 470–474. <https://doi.org/10.1109/ICIET56899.2023.10111353>
- Niu, B., Lai, C., Zheng, Z., Qi, Z., & Dai, Z. (2025). AI quality control in competitive recycling facing material contamination. *International Journal of Production Economics*, 282, 109541. <https://doi.org/https://doi.org/10.1016/j.ijpe.2025.109541>
- Nugroho, H. A., & Frannita, E. L. (2021). Thyroid Cancer Classification using Transfer Learning. *2021 International Conference on Computer Science and Engineering (IC2SE)*, 1, 1–5. <https://doi.org/10.1109/IC2SE52832.2021.9791905>
- Nurhayani, N., Putri, S. R., & Darmawan, A. (2023). Analisis Pengendalian Kualitas Produk Outsole Sepatu Casual menggunakan Metode Six Sigma DMAIC dan Kaizen 6S. *Jurnal Teknik Industri: Jurnal Hasil Penelitian Dan Karya Ilmiah Dalam Bidang Teknik Industri*, 9(1), 248–258. <https://doi.org/http://dx.doi.org/10.24014/jti.v9i1.22449>
- Pérez-Calabuig, A. M., Pradana-López, S., Cancilla, J. C., Mena, M. L., & Torrecilla, J. S. (2025). AI-powered optical quality control of yogurt: Detecting melamine adulteration and monitoring shelf-life. *Applied Food Research*, 5(2), 101510. <https://doi.org/https://doi.org/10.1016/j.afres.2025.101510>
- Ratnayake, R. M. O. B., & Ratnayake, R. M. C. (2023). Use of Circular Economy Goals in Product Development: A Case Study from a Water-Proof Shoe Cover. *2023 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, 1245–1250. <https://doi.org/10.1109/IEEM58616.2023.10406339>
- Rossi, M., Papetti, A., Marconi, M., & Germani, M. (2021). Life cycle assessment of a leather shoe supply chain. *International Journal of Sustainable Engineering*, 14(4), 686–703. <https://doi.org/10.1080/19397038.2021.1920643>
- Su, J., Ding, H., Wang, W., Huang, X., Zhang, S., Lewis, R., Meli, E., Liu, Q., & Zhou, Z. (2025). Experimental study on the effect of brake shoe pressure on wheel wear and fatigue damage behavior during tread braking. *Wear*, 571, 205840. <https://doi.org/https://doi.org/10.1016/j.wear.2025.205840>
- Suhartini, & Ramadhan, M. (2021). Analisis Pengendalian Kualitas Produksi Untuk Mengurangi Cacat Pada Produk Sepatu Menggunakan Metode Six Sigma dan Kaizen. *Matrik : Jurnal Manajemen Dan Teknik Industri Produksi*, 22(1). <https://doi.org/https://doi.org/10.30587/matrik.v22i1.2517>
- Vong, T., Jeenanunta, C., Tunpan, A., & Sirimarnkit, N. (2021). The Low Computation and Real-Time Shoe Detection with Timestamp for Production Tracking in Shoe Manufacturing. *2021 16th International Joint Symposium on Artificial Intelligence and Natural Language Processing (ISAI-NLP)*, 1–5. <https://doi.org/10.1109/iSAI-NLP54397.2021.9678163>
- World Footwear. (2024). *The World Footwear Yearbook 2025*.
- Yiting, L., Hongpeng, Z., Peng, Z., Yin, W., Yiming, H., Xinran, W., & Wenxuan, G. (2026). AI for smart wastewater treatment plants: A review of physics-informed water quality modeling, optimization, and advanced control. *Journal of Environmental Management*, 401, 128949. <https://doi.org/https://doi.org/10.1016/j.jenvman.2026.128949>