TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

Pengembangan Intelligent Leather Inspection Method Berbasis Interpretable Artificial Intelligence

Eka Legya Frannita[1,*], Dwi Wulandari[2], Naimah Putri[2,] , Atiqa Rahmawati[2,] , Alifia Revan Prananda[3]

[1] Program Studi Teknologi Pengolahan Produk Kulit, Politeknik ATK Yogyakarta, Yogyakarta, Indonesia
[2] Program Studi Teknologi Pengolahan Kulit, Politeknik ATK Yogyakarta, Yogyakarta, Indonesia
[3] Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Tidar, Magelang, Indonesia
Email: [1,*]eka.legya@atk.ac.id, [2]dwiwulandari@atk.ac.id, [3]naimah@atk.ac.id, [4]atiqa.rahmawati@atk.ac.id, [5]revan@untidar.ac.id
Email Penulis Korespondensi: eka.legya@atk.ac.id

Abstrak−Revolusi industri 4.0 yang ditandai dengan adopsi kecerdasan buatan dan otomasi telah mentransformasi proses inspeksi kualitas di sektor manufaktur. Namun, industri penyamakan kulit masih bergantung pada metode konvensional berbasis pemeriksaan visual oleh operator, yang rentan terhadap subjektivitas, variabilitas antar-operator, dan ketidakkonsistenan hasil. Penelitian ini mengusulkan kerangka kerja deep learning berbasis arsitektur NasNet-Large yang diintegrasikan dengan LIME (Local Interpretable Model-Agnostic Explanations) untuk mengotomasi deteksi cacat dan klasifikasi kualitas kulit secara objektif. Dataset yang digunakan dalam penelitian ini adalah data citra digital kulit pikel yang terdiri dari empat jenis grade kulit. Dataset dilengkapi oleh ground truth kualitas kulit atau grade kulit dan interpretasi dari leather expert. Eksperimen berhasil menghasilkan akurasi yang cukup stabil yakni 75% untuk data training dan validation, dan menunjukkan peningkatan pada data testing menjadi 79%. Hasil visualisasi LIME menunjukkan konvergensi antara area defek yang teridentifikasi dengan referensi ground truth dari pakar. Hal ini menunjukkan bahwa model yang dikembangkan kemampuan yang sangat baik dalam melakukan inspeksi kualitas kulit. Dengan demikian, pendekatan yang diusulkan tidak hanya meningkatkan efisiensi inspeksi kualitas kulit tetapi juga memberikan interpretasi yang transparan yang mana sangat mendukung penerapan AI yang lebih andal dalam industri penyamakan kulit.

Kata Kunci: Artificial Intelligence; Inspeksi Kualitas Kulit; Interpretable AI; LIME; Nasnet Large

Abstract−The Industry 4.0 revolution, characterized by the widespread adoption of artificial intelligence and automation, has fundamentally transformed quality inspection processes in manufacturing sectors. Nevertheless, the leather tanning industry continues to rely on conventional visual inspection methods conducted by human operators, which are inherently susceptible to subjectivity, inter-operator variability, and inconsistent outcomes. This study proposes an integrated deep learning framework utilizing the NasNet-Large architecture combined with Local Interpretable Model-Agnostic Explanations (LIME) to automate objective defect detection and quality classification of pickled leather. The research employs a digital image dataset comprising four distinct leather grade categories, each annotated with expert-validated ground truth labels and professional interpretations. Experimental results demonstrate consistent model performance with 75% accuracy in both training and validation phases while achieving improved testing accuracy of 79%. LIME-based interpretability analysis reveals significant spatial convergence between model-identified defect regions and expert-annotated ground truth references. These findings indicate that the developed model exhibits remarkable competence in replicating professional leather quality inspection capabilities. The proposed approach not only enhances inspection efficiency by reducing human-dependent errors but also provides transparent decision-making interpretability - a critical requirement for reliable AI implementation in industrial applications. This research contributes to the advancement of explainable AI systems in material quality assessment, offering methodological innovation and practical implementation value for the leather manufacturing sector.

Keywords: Artificial Intelligence; Interpretable AI; Leather Inspection; LIME; Nasnet Large

1. PENDAHULUAN

Seiring dengan perkembangan dan penerapan teknologi otomasi dan kecerdasan buatan, era manufaktur cerdas mengalami percepatan yang sangat signifikan termasuk pada proses inspeksi atau quality control produk (Xu et al., 2023). Namun sampai saat ini pada industri penyamakan kulit dan pengolahan produk berbahan dasar kulit, proses inspeksi atau quality control yang meliputi proses identifikasi cacat dan penentuan grade atau kualitas kulit masih dilakukan secara manual dengan cara melakukan pengamatan langsung pada objek. Prosedur ini membutuhkan tingkat pengalaman dan ketelitian yang tinggi, serta sangat dipengaruhi oleh subjektivitas individu yang mana menyebabkan rendahnya konsistensi dan stabilitas hasil inspeksi, serta mengurangi efisiensi proses produksi. Prosedur ini juga dapat berpotensi menghambat peningkatan daya saing sehingga berakibat pada penurunan profit yang cukup signifikan (Z. Chen et al., 2024)(Omoloso et al., 2021). Saat ini, dunia sedang menghadapi era tekanan ekonomi global yang jugssssa mempengaruhi berbagai sektor industri termasuk industri penyamakan kulit dan pengolahan produk berbahan dasar kulit. Untuk menghadapi hal tersebut, pemanfaatan teknologi cerdas dan otomasi sangat diperlukan diberbagai divisi termasuk pada proses inspeksi atau quality control proses penyamakan kulit dan pengolahan produk berbahan dasar kulit guna untuk mengefisiensikan proses dan mendapatkan hasil dengan kualitas terbaik (Z. Chen et al., 2024)(Cao et al., 2025).

Sebagai salah satu alternatif solusi untuk permasalahan di atas, peneliti telah melakukan beberapa penelitian terkait penerapan teknologi otomasi dan kecerdasan buatan untuk proses inspeksi atau quality control proses penyamakan kulit dan pengolahan produk berbahan dasar kulit khususnya pada proses pada proses identifikasi cacat pada permukaan kulit yang mana merupakan proses ini sangat penting mengingat adanya cacat pada permukaan kulit akan sangat mempengaruhi grade atau kualitas kulit. Penelitian sebelumnya telah berhasil memperoleh perfoma yang sangat baik yakni rata-rata akurasi lebih dari 80% dengan menerapkan berbagai arsitektur convolutional neural network

Copyright © 2025 the author, Page 113
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

(CNN) untuk mengidentifikasi jenis-jenis cacat pada permukaan kulit (Frannita & Prananda, 2024; A. R. Prananda & Frannita, 2023a, 2024a, 2024b). Penelitian serupa juga telah dilakukan oleh beberapa peneliti terdahulu seperti penelitian yang diusulkan oleh Chen dkk (Z. Chen et al., 2024) tentang eksperimen beberapa versi YOLO untuk mengidentifikasi cacat pada permukaan kulit. Penelitian ini berhasil melakukan experimen pada YOLOv5 hingga YOLOv8 dan menghasilkan mAP tertinggi sebesar 85%, presisi sebesar 90,9%, dan recall sebesar 81,8%. Wenbin Chen dkk (W. Chen et al., 2025) juga mengusulkan penelitian serupa yakni penggunaan YOLOv5 untuk mendeteksi cacat pada permukaan kulit dan memperoleh mAP sebesar 87%. Penelitian lain yakni penelitian yang diusulkan oleh Mai dkk (Mai et al., 2024) tentang pengembangan kombinasi Gausian Filter dan CNN model untuk mengidentikasi jenis-jenis cacat pada permukaan kulit. Penelitian ini menggunakan beberapa arsitektur seperti Xception, InceptionV3, ResNet50V2, VGG19, dan VGG16. Berdasarkan hasil training dan testing yang telah dilakukan, VGG16 menghasilkan akurasi tertinggi yakni 100% dalam mengidentifkasi jenis-jenis cacat pada permukaan kulit. Penelitian lain yang diusulkan oleh Jin dkk (Jin & Lu, 2023) tentang penerapan YOLOv5 untuk mendeteksi cacat pada permukaan kulit telah berhasil meningkatkan mAP hingga 4%. Wang dkk (Wang et al., 2024) mengembangkan GDN (Ghost-DFC Attention-NWD) untuk meningkatkan performa YOLOv7 dan berhasil memperoleh mAP sebesar 87,8% serta menurunkan komputasi hingga 44,36%. Bhanothu dkk (Bhanothu et al., 2024) menerapkan beberapa arsitektur CNN seperti LeNet-5, VGG-13, VGG-16, VGG-19, ResNet-50, MobileNet and MobileNetV2 untuk mengidentifikasi jenis-jenis cacat pada permukaan kulit. Hasil eksperimen yang dilakukan dalam penelitian tersebut menghasil mode VGG16 dengan akurasi tertinggi sebesar 96,65%. He dkk (He et al., 2024) mengembangkan YOLOv5 untuk mendeteksi cacat pada permukaan kulit dan berhasil menghasilkan mAP 79,5%. Akter dkk (Akter et al., 2024) menggunakan enam arsitektur CNN seperti MobileNet, Softmax, DensNet, ResNet, dan VGG. Berdasarkan eksperimen yang dilakukan dalam penelitian, DenseNet berhasil menghasilkan akurasi tertinggi sebesar 89,788%.

Penelitian-penelitian di atas telah berhasil memberikan hasil yang cukup signifikan, namun penerapan artificial intelligence pada dasarnya masih memiliki kelemahan mengingat proses black-box yang terjadi selama training dan testing (Samek et al., 2021)(Setzu et al., 2021). Pada kasus-kasus tertentu diperlukan interpretable atau penjelasan mengenai hasil dari model deep learning terutama untuk kasus-kasus yang sifatnya krusial (Raees et al., 2024)(Hosain et al., 2024). Proses inspeksi atau quality control merupakan contoh proses yang krusial karena hasil dari proses ini akan sangat berpengaruh pada hasil akhir atau end-product. Oleh karena itu, alternatif solusi yang tidak hanya mampu melakukan deteksi atau identifikasi namun juga mampu memberikan interpretable atau penjelasan terhadap hasil terdetksi tersebut dibutuhkan dalam kasus ini agar pengembangan intelligent system untuk proses inspeksi atau quality control dapat berjalan dengan lebih optimal.

Perkembangan artificial intelligence saat ini sudah semakin tinggi. Untuk menanggulangi permasalahan proses black-box dalam arsitektur metode artificial intelligence, para peneliti terdahulu telah mengembangkan explainable dan interpretable artificial intelligence atau yang dikenal dengan istilah XAI dan IAI yang memberikan kebaruan berupa interpretable atau penjelasan dari hasil arsitektur artificial intelligence. Di beberapa kasus seperti kasus medis, pendekatan ini sangat memberikan dampak yang signifikan. Keraguan akan hasil dari arsitektur deep learning atau machine learning yang dialami oleh tenaga medis dapat ditanggulangi dengan hasil dari XAI atau IAI (Alves et al., 2021)(Deperlioglu et al., 2022)(Gabeff et al., 2021)(A. R. Prananda & Frannita, 2023b). Oleh karena itu, penelitian ini bertujuan untuk mengadopsi metode IAI pada kasus inspeksi atau quality control. Adapun kontribusi dari penelitian ini adalah pengembangan intelligent leather inspection method berbasis interpretable artificial intelligence (IAI).

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

2.1.1 Pendekatan Penelitian atau Kerangka Berfikir

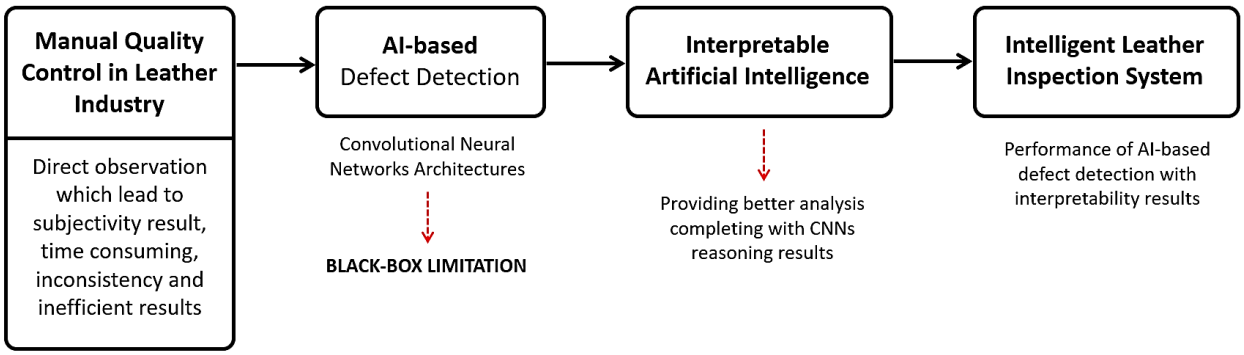
Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen berbasis artificial intelligence (AI), khususnya interpretable artificial intelligence (IAI). Pendekatan ini bertujuan untuk mengembangkan dan menguji model cerdas yang tidak hanya mampu mengidentifikasi cacat pada permukaan kulit secara otomatis dan akurat, tetapi juga mampu memberikan penjelasan (interpretable) terhadap hasil prediksi yang diberikan. Proses eksperimen dilakukan dengan membandingkan performa model-model CNN dan IAI dalam aspek akurasi serta interpretabilitas hasil. Secara garis besar pendekatan penelitian dan kerangka berfikir dalam penelitian ini diilustrasikan pada Gambar 1 dan Tabel 1.

Tabel 1. Deskripsi pendekatan penelitian dan kerangka berfikir dari penelitian yang diusulkan

Komponen	Deskripsi
Jenis pendekatan	Kuantitatif
Metode penelitian	Eksperimen komputasional – Menguji performa model CNN dan IAI untuk menentukan kualitas kulit serta memberikan interpretasi dari hasil CNN yang diperoleh
Jenis data yang digunakan	Data citra digital permukaan kulit yang cacat, dilengkapi label jenis cacat
Tenik analisis	Matriks evaluasi klasifikasi (akurasi) dan evaluasi visual dari hasil IAI

Copyright © 2025 the author, Page 114
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425



Gambar 1. Kerangka berfikir dari penelitian yang diusulkan

Gambar 1 menunjukkan kerangka berfikir dari penelitian yang diusulkan dimana masalah yang diangkat merupakan masalah tentang proses inspeksi atau quality control yang dilakukan secara manual sehingga menyebabkan berbagai masalah. Penyelesaian dari masalah tersebut adalah pemanfaatan AI untuk membantu proses inspeksi atau quality control sehingga dapat dilakukan dengan lebih efektif dan efisien. Namun AI sendiri masih memiliki keterbatasan yakni black-box principal yang ada dalam arsitektur AI. Sehingga penelitian ini mengusulkan interpretable artificial intelligence atau IAI agar hasil dari AI menjadi lebih transparan.

2.1.2 Hipotesis

Hipotesis dalam penelitian yang diusulkan adalah Penerapan metode interpretable artificial intelligence (IAI) pada proses identifikasi cacat permukaan kulit dapat meningkatkan kualitas hasil inspeksi yang mencakup aspek akurasi dan interpretabilitas dibandingkan metode CNN konvensional.

2.1.3 Kajian Teknik/Metode Analisis

Arsitektuk CNN yang digunakan dalam penelitian ini adalah arsitektur NasNet. NASNet (Neural Architecture Search Network) merupakan dua pendekatan penting dalam bidang pembelajaran mesin yang berkontribusi pada peningkatan kinerja model serta pemahaman terhadap hasil prediksi. NASNet merupakan arsitektur jaringan saraf yang dirancang secara otomatis menggunakan teknik neural architecture search (NAS), yaitu suatu metode pencarian arsitektur optimal melalui eksplorasi ruang desain model secara sistematis dan berbasis algoritma (A. Prananda & Frannita, 2023). NASNet dikembangkan dengan prinsip bahwa bagian-bagian kecil dari jaringan, yang disebut sebagai cell, dapat dioptimalkan terlebih dahulu dan kemudian diulang-ulang untuk membentuk arsitektur akhir yang lebih besar. Hal ini memungkinkan pengembangan jaringan yang sangat efisien dan efektif dalam berbagai tugas visi komputer, seperti klasifikasi citra dan deteksi objek, dengan kinerja yang mampu melampaui banyak arsitektur yang dirancang secara manual. NASNet juga menunjukkan efisiensi tinggi dalam hal komputasi, karena arsitektur yang dihasilkan dapat disesuaikan untuk berbagai batasan sumber daya, termasuk penggunaan pada perangkat dengan daya komputasi rendah (Zoph et al., 2018).

Sedangkan metode interpretable yang digunakan dalam penelitian ini adalah LIME (Local Interpretable Model-agnostic Explanations). LIME merupakan pendekatan yang berfokus pada interpretabilitas model pembelajaran mesin. Teknik ini dikembangkan untuk memberikan penjelasan lokal yang dapat dimengerti oleh manusia terhadap prediksi yang dihasilkan oleh model-model kompleks dan tidak transparan, seperti random forest, support vector machine, atau jaringan saraf dalam. LIME bekerja dengan cara membangun model interpretable secara lokal di sekitar prediksi tertentu dengan mensintesis data baru melalui perturbasi data asli dan mengobservasi perubahan dalam hasil prediksi. Dengan pendekatan ini, LIME dapat mengidentifikasi fitur-fitur yang paling berpengaruh terhadap keputusan model untuk satu observasi tertentu. Keunggulan utama LIME adalah sifatnya yang model-agnostik, yang berarti dapat diterapkan pada berbagai jenis model tanpa perlu mengubah struktur internal model tersebut. Penggunaan LIME sangat penting dalam konteks explainable AI (XAI), karena membantu meningkatkan transparansi dan akuntabilitas, khususnya dalam aplikasi-aplikasi yang berdampak tinggi seperti diagnosis medis, deteksi fraud, dan sistem rekomendasi (An et al., 2025)(Badhon et al., 2025).

2.2 Tahapan Penelitian

Secara umum tahapan penelitian ini terdiri atas lima proses yakni tahap pengumpulan data, tahap training data, tahap testing data, tahap evaluasi menggunakan interpretable artificial intelligence (IAI) dan tahap analisis hasil sebagaimana diilustrasikan pada Gambar 2.

This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425



Gambar 2. Tahapan Penelitian

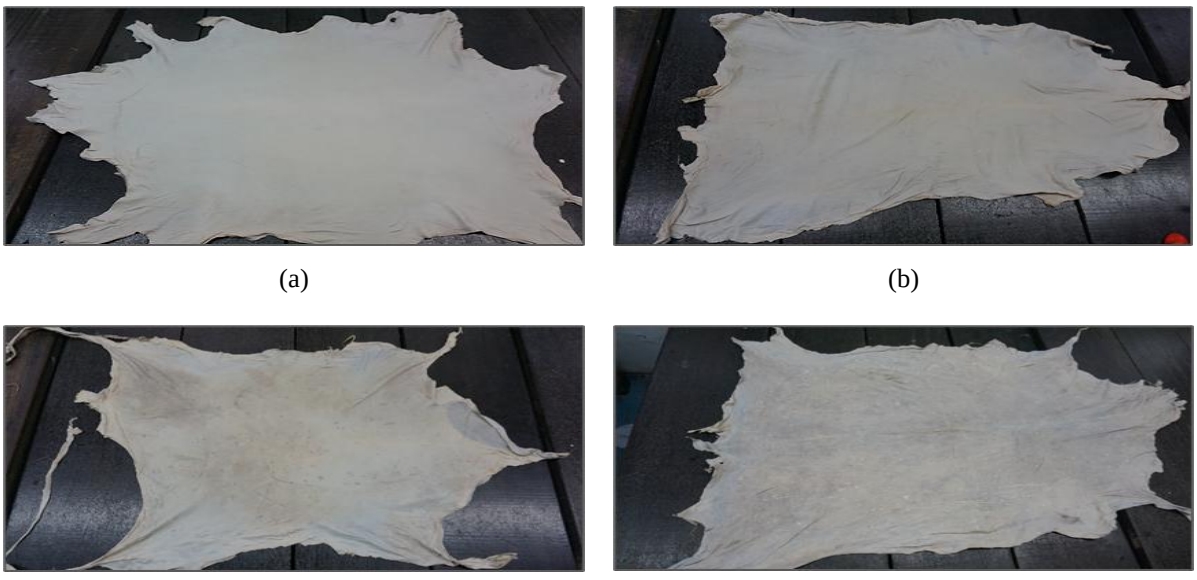
2.2.1 Pengumpulan Data

Proses pengumpulan data dilakukan di PT. Budi Makmur Jayamurni. Data yang dikumpulkan dalam penelitian ini merupakan data kulit pikel dengan grade i-iv, v, iv dan R. Penjelasan untuk masing-masing grade dapat dilihat pada Tabel 2. Proses pengumpulan data dilakukan dengan menggunakan kamera resolusi 24 megapiksel dan penerangan yang cukup. Deskripsi data yang telah dikumpulkan dideskripsikan pada Tabel 2.

Tabel 2. Deskripsi dataset yang digunakan dalam penelitian yang diusulkan

Komponen	Deskripsi
Jenis data	Digital leather pickle images
Dimensi	6000 x 3376 piksel
Ground truth	Ground truth yang tersedia merupakan ground truth klasifikasi. Data terklasifikasi menjadi empat kelas yakni grade i-iv : merupakan grade terbaik yang meliputi grade i hingga grade iv grade v : merupakan grade kulit dengan kualitas nomor 2 grade vi : merupakan grade kulit dengan kualitas nomor 3 grade R atau reject : merupakan grade kulit dengan kualitas reject
Proporsi data	Jumlah data untuk masing-masing kelas adalah sebagai berikut: grade i-iv : 50 data grade v : 50 data grade vi : 50 data grade R atau reject : 50 data
Sumber data	Data merupakan data primer yang diambil langsung oleh peneliti di PT Budi Makmur Jayamurni

Gambar berikut menunjukkan contoh dataset yang digunakan dalam penelitian ini. Terdapat empat jenis grade atau kualitas kulit yang digunakan dalam penelitian sesuai dengan deskripsi pada Tabel 2.



(a) (b)

(c) (d)

Gambar 3. Contoh dataset yang digunakan: (a) kulit grade i-iv, (b) kulit grade v, (c) kulit grade vi dan (d) kulit grade R

Copyright © 2025 the author, Page 116
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

Berdasarkan Gambar 3, keempat jenis grade atau kualitas kulit hampir tidak memiliki perbedaan yang signifikan. Namun apabila diteliti lebih detail akan terlihat defek-defek kulit yang diilustrasikan dengan warna coklat samar. Semakin banyak defek dalam satu lembar kulit pikel maka grade atau kualitas kulit akan semakin rendah. Gambar 3(a) menunjukkan kulit pikel grade i-iv yang merupakan grade terbaik dari kulit pikel. Pada gambar ini kulit terlihat putih bersih dan tidak memiliki warna coklat samar. Berbeda dengan Gambar 3(b) hingga Gambar 3(d) yang memiliki noda atau defek dengan warna yang bervariasi seperti coklat, abu, atau bercak putih.

2.2.2 Training dan Testing Data Menggunakan CNN

Penelitian ini menggunakan arsitektur NasNet Large dengan rincian arsitektur sebagai berikut:

Tabel 3. Deskripsi NasNet Large

Layer	Deskripsi
Input Layer	331x331 piksel, 3 kanal (RGB)
Stem Convolution Layer	Jumlah filter: 96 Ukuran kernel: 3x3 Stride: 2 Padding: 'same'
Batch Normalization	Normalisasi fitur
Activation Layer	ReLU
Reduction Cell 0	Blok khusus untuk downsampling awal Menggabungkan operasi: separable conv, pooling, concat
Normal Cell x6	Cell yang mempertahankan ukuran spasial Berisi kombinasi depthwise separable conv (misal 5x5, 3x3), add, dan concat
Reduction Cell 1	Blok downsampling kedua Mengurangi ukuran spasial dan melipatgandakan kanal
Normal Cell x6	Diulang pada resolusi menengah Mengolah fitur dalam dimensi lebih rendah
Reduction Cell 2	Blok downsampling ketiga Output spasial makin kecil, channel meningkat
Normal Cell x6	Operasi konvolusional terakhir
Global Average Pooling	Ukuran output: 1x1x4032
Fully Connected Layer (Dense)	4 (sesuai dengan jumlah kelas)
Activation Output Layer	Softmax

Tabel 3 merupakan rincian layer yang digunakan dalam arsitektur NasNet Large yang mana berisi penejelasan detail mengenai jenis layer dan spesifiaksi dari masing-masing layer termasuk input dan output dari masing-masing layer. Dalam penggunaan arsitektur deep learning, pemahaman mengenai masing-masing komponen sangat diperlukan agar proses training dapat disesuaikan dengan kndisi dataset yang digunakan.

2.2.3 Penerapan Interpretable Artificial Intelligence

Metode interpretable artificial intelligence atau IAI yang digunakan dalam penelitian ini adalah metode LIME (Local Interpretable Model-agnostic Explanations). LIME bekerja dengan membuat instance baru yang dipermutasi dari predicted model dengan mempertimbangkan rata-rata dan standar deviasi dari data asli sebagaimana diformulasikan pada persamaan (1).

$$\text{Explanation (x)} = \underset{g \in G}{\operatorname{argmin}}\, L(f, g, \pi_x) + \Omega(g) \tag{1}$$

Dimana L adalah loss yang dihasilkan oleh model. Symbol f mengilustrasikan predicted model, sedangkan g mengilustrasikan interpretable model. $\Omega(g)$ merupakan formula yang berfungsi untuk menjaga agar kompleksitas model selalu kecil. Secara garis besar, algoritma LIME digambarkan melalui Algorithm 1 (A. R. Prananda & Frannita, 2023b).

Tabel 4. The workflow of LIME

Algorithm 1. The workflow of LIME
1 : input: original trained model f , N samples of data, instance x, interpretable model x', sameness kernel πx and explanation length K
2 : Z ← {} *Z is a dataset*
3 : for a € {1, 2, 3, ..., N} do
4 : zi' ← sample_near_of(x') *using Euclidean distance*
5 : Z ← Z ∪(zi',$f(zi)$,$\pi x(zi)$)
6 : end for
7 : Ω ← K-Lasso (Z, K) *with zi' as features, f (z) as the prediction target*

Copyright © 2025 the author, Page 117
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

Algorithm 1. The workflow of LIME
8 : return Ω

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Penelitian ini bertujuan untuk mengembangkan metode identifikasi kualitas atau grade kulit pikel dengan menggunakan pendekatan artificial intelligence yang dilengkapi dengan LIME sebagai bentuk interpretable dari hasil arsitektur deep learning yang digunakan. Data yang digunakan dalam penelitian ini adalah data kulit pikel dari hewan kambing dan domba berupa citra digital. Kulit pikel adalah kulit mentah yang telah mengalami proses pengolahan hingga tahap pengasaman (pencelupan dalam larutan asam dan garam). Gambar 4 merupakan contoh dari bagaimana kulit hewan diolah menjadi kulit pikel.



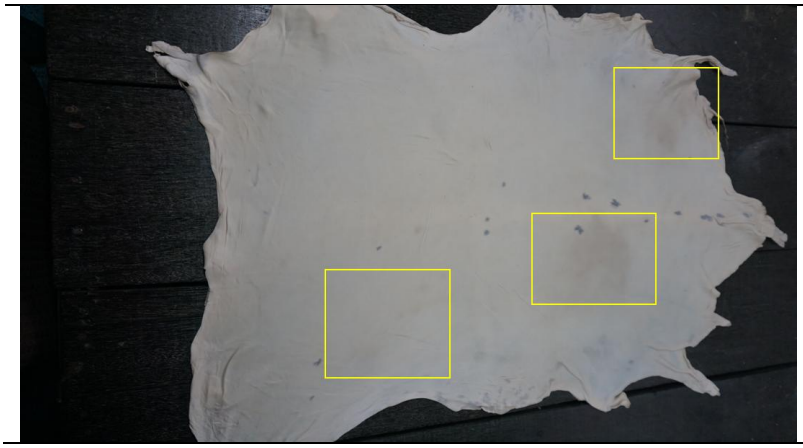
(a) (b)

Gambar 4. Ilustrasi kulit domba : (a) kulit domba yang masih berbulu dan (b) kulit pikel

Gambar 4(a) menunjukkan kulit hewan yang asli dan belum mengalami proses penyamakan. Sedangkan Gambar 4(b) merupakan hasil penyamakan awal yakni kulit mentah yang mengalami proses pembersihan bulu dan pengasaman menggunakan larutan asam dan garam. Dalam penelitian ini, kulit pikel sebagaimana diilustrasikan pada Gambar 4(b) didokumentasikan dalam bentuk citra digital kemudian diberi label (ground truth) untuk diproses oleh arsitektur deep learning.

Proses dokumentasi atau pengambilan data dilakukan dengan menggunakan kamera digital dengan resolusi 24 megapiksel dan dilengkapi dengan penerangan yang cukup. Selama proses pengambilan data, peneliti didampingi oleh ahli atau leather expert dari PT Budi Makmur Jayamurni. Proses pendampingan bertujuan agar pelaksanaan pengambilan data sesuai dengan karakteristik dan prosedur. Selain itu ahli atau leather expert juga memberikan keterangan ground truth atau grade dari masing-masing kulit yang diambil. Selain ground truth berupa grade atau kualitas kulit, leather expert juga memberikan ground truth berupa interpretable. Berikut adalah contoh interpretable yang diberikan oleh leather expert.

Tabel 5. Contoh interpretable dari leather expert

Contoh Dataset	Interpretable/Penjelasan
	Data di samping merupakan jenis grade i-iv karena terdapat bercak coklat muda. Bercak coklat ditandai dengan anotasi warna kuning. Bercak coklat menandakan abnormality object yang akan menurunkan kualitas atau grade kulit.

Dari data Tabel 5 di atas, selanjutnya dilakukan proses training dengan komposisi set-up yang dapat dilihat pada Tabel 6 sebagai berikut:

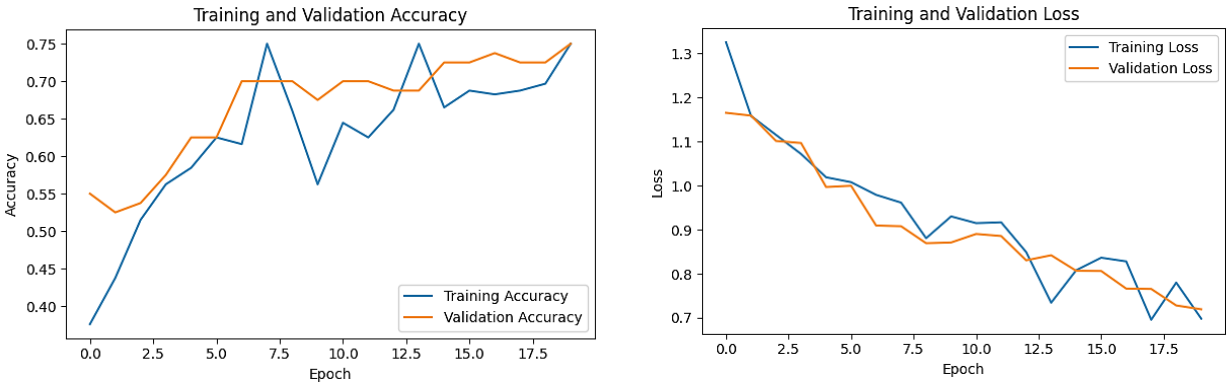
Copyright © 2025 the author, Page 118
This Journal is licensed under a Creative Commons Attribution 4.0 International License

TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

Tabel 6. Set-up proses training

Komponen	Deskripsi
Proporsi data:	
training	80% dari total data
validation	10% dari total data
testing	10% dari total data
Jumlah epoch	20
Activation function	SoftMax
Optimizer	Adam
Learning rate	0,0001
Batch size	16

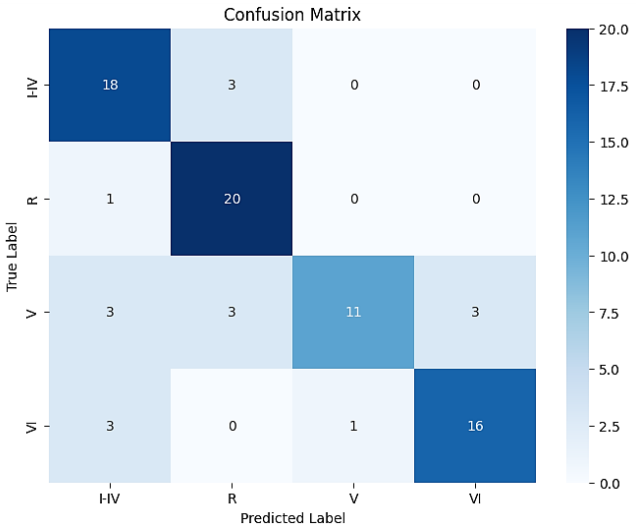
Tabel 6 merupakan set-up architecture yang digunakan dalam proses training. Komponen dari Tabel 6 telah disesuaikan dengan kebutuhan arsitektur NasNet Large dan karakteristik dataset. Berikut adalah hasil akurasi dan loss selama proses training berlangsung.



(a) (b)

Gambar 5. Hasil training : (a) akurasi dan (b) loss

Gambar 5 menunjukkan hasil akurasi dan loss selama proses training. Pada Gambar 5(a), garis biru menunjukkan akurasi yang diperoleh dari data training, sedangkan garis merah menunjukkan hasil akurasi pada data validation. Pada Gambar 5(b), garis biru menunjukkan loss dari data training sedangkan garis merah menunjukkan loss pada data validation. Setelah proses training selesai, selanjutnya model hasil training disimpan untuk dilakukan proses testing. Hasil dari proses testing dapat dilihat pada Gambar 6.



Gambar 6. Confusion Matriks dari hasil testing

3.2 Pembahasan

Berdasarkan hasil training seperti yang diilustrasikan pada Gambar 5, terlihat bahwa akurasi pada data training dan data validation cukup fluktuatif namun mengalami kenaikan dengan titik stabil pada akurasi sebesar 0,75. Hal yang sama

Copyright © 2025 the author, Page 119
This Journal is licensed under a Creative Commons Attribution 4.0 International License

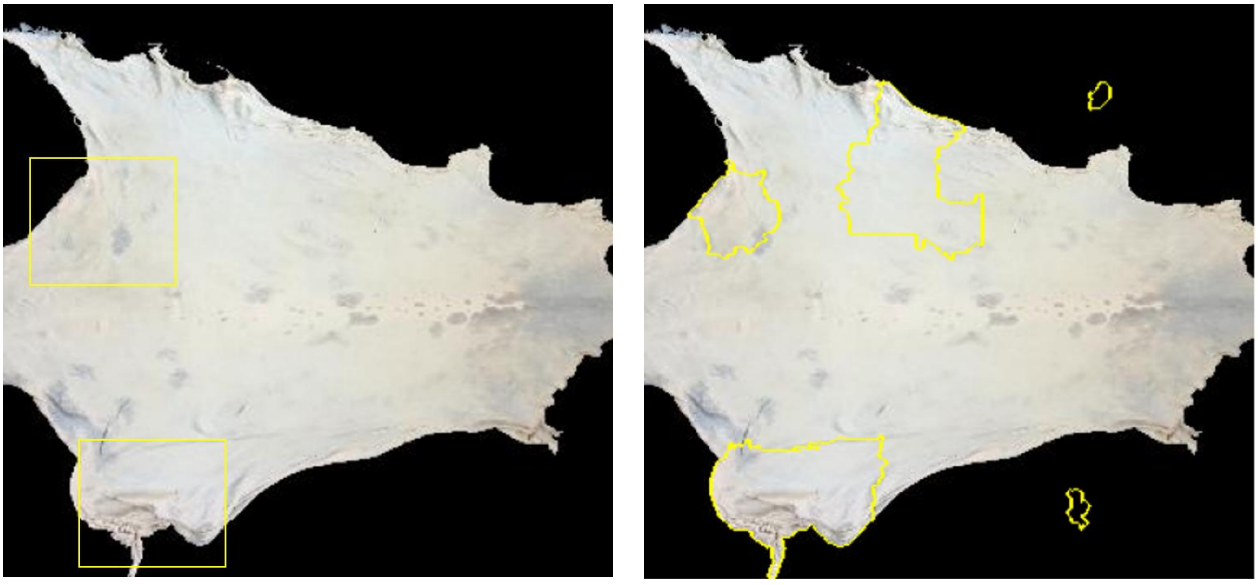
TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

terjadi pada perhitungan loss baik pada data training maupun data testing. Berdasarkan Gambar 4 dapat diidentifikasi bahwa loss selama proses training selalu mengalami penurunan dengan titik stabil pada 0,0,69. Gambar 6 menunjukkan hasil confusion matrix dari hasil testing. berdasarkan hasil tersebut terlihat bahwa Sebagian besar data telah diklasifikasikan dengan baik namun terdapat beberapa data yang mengalami kesalahan klasifikasi. Kelas dengan jumlah kesalahan klasifikasi yang cukup banyak adalah kelas v atau grade v. Untuk melakukan analisis lebih detail selanjutnya dilakukan analisis klasifikasi pada masing-masing kelas. Hasil dari analisis masing-masing kelas grade dapat dilihat pada Tabel 7.

Tabel 7. Analisis pada masing-masing grade

Kelas/Grade	precision	recall	F1-score
Grade i-iv	0,72	0,86	0,78
Grade R	0,77	0,95	0,85
Grade v	0,92	0,55	0,69
Grade vi	0,84	0,80	0,82

Berdasarkan hasil pada Tabel 7, dapat diidentifikasi bahwa kelas dengan hasil klasifikasi terbaik adalah grade vi yang artinya model telah berhasil mengenali karakteristik grade vi dan mampu mengidentifikasi atau mengenali data sebagai grade vi dengan baik pada saat proses testing. sebaliknya, grade v merupakan kelas dengan jumlah kesalahan klasifikasi paling banyak. Hal ini disebabkan karena kemiripan karakteristik dengan kelas atau grade yang lain. Dari hasil pada Tabel 7 selanjutnya diperoleh akurasi testing sebesar 0.79. Selain data di atas, hasil juga dilengkapi dengan interpretable dengan menggunakan LIME. Berikut adalah visualisasi interpretable yang dihasilkan.



(a) (b)

Gambar 7. Hasil IAI : (a) anotasi dari leather expert dan (b) hasil LIME

Gambar 7 menunjukkan perbandingan antara hasil anotasi interpretable dari leather expert dan hasil LIME. Garis kuning menunjukkan abnormality object yang mempengaruhi penentuan grade. Secara klasifikasi, model telah berhasil menentukan bahwa Gambar 7 merupakan grade i-iv. Namun secara interpretasi terdapat sedikit perbedaan. Gambar 7(a) menunjukkan bahwa menurut leather expert hanya terdapat dua area yang mengandung abnormality sedangkan hasil LIME menunjukkan bahwa terdapat tiga area yang mengandung abnormality. Pada dasarnya secara umum hasil interpretasi dari LIME cukup mewakili hasil dari leather expert. Setelah dilakukan analisis, masih terdapat area lain yang dianggap sebagai abnormality karena terdapat sedikit bercak coklat tipis yang mana kondisi ini juga dianggap sebagai sebuah abnormality oleh LIME. Namun, dalam perusahaan sering kali terdapat toleransi terkait dengan abnormality objek sehingga untuk bercak yang tidak terlalu nampak atau tipis dapat ditoleransi. Sehingga dapat disimpulkan bahwa hasil dari LIME sudah sangat mendekati hasil dari leather expert sebagai ground truth.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan arsitektur deep learning yang dilengkapi dengan interpretasi hasil. Metode yang digunakan dalam penelitian ini adalah NasNet Large yang dikombinasikan dengan LIME. Penelitian diawali dengan pengambilan data dan pembuatan ground truth yang dilengkapi dengan interpretasi. Selanjutnya dilakukan pengembangan arsitektur NasNet Large yang disesuaikan dengan karakteristik dataset dan dikombinasikan

Copyright © 2025 the author, Page 120
This Journal is licensed under a Creative Commons Attribution 4.0 International License


TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

dengan LIME. Tahap selanjutnya merupakan tahap training dan testing. Berdasarkan hasil training dan testing, diperoleh akurasi pada data training sebesar 0,75, akurasi pada data validation sebesar 0,75 dan akurasi pada data testing sebesar 0,79. Selain itu, berdasarkan hasil visualisasi dari interpretasi LIME diperoleh hasil bahwa LIME berhasil mengidentifikasi abnormality pada area yang sama dengan ground truth dari leather expert. Sehingga dapat disimpulkan bahwa hasil dari LIME sudah sangat mendekati hasil dari leather expert sebagai ground truth.

UCAPAN TERIKAMASIH

Artikel jurnal ini ditulis oleh Tim Peneliti Politeknik ATK Yogyakarta berkolaborasi dengan Tim Peneliti Universitas Tidar berdasarkan hasil penelitian dengan judul Pengembangan Rancang Bangun Alat Deteksi Defek dan Grading Kulit Otomatis Pada Kulit Pikel Kambing dan Domba yang dibiayai oleh Badan Pengembangan Sumber Daya Manusia Industri (BPSDMI) Kementerian Perindustrian melalui Program Hibah Penelitian SPIRIT Tahun 2024. Penulis juga mengucapkan terimakasih kepada PT. Budi Makmur Jayamurni sebagai mitra penelitian yang telah menyediakan dataset uji.

REFERENCES

Akter, T., Samman, A. S. A., Lily, A. H., Rahman, M. S., Prova, N. N. I., & Joy, M. I. K. (2024). Deep Learning Approaches for Multi Class Leather Texture Defect Classifcation. *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1–6. https://doi.org/10.1109/ICCCNT61001.2024.10725952

Alves, M. A., Castro, G. Z., Oliveira, B. A. S., Ferreira, L. A., Ramírez, J. A., Silva, R., & Guimarães, F. G. (2021). Explaining machine learning based diagnosis of COVID-19 from routine blood tests with decision trees and criteria graphs. *Computers in Biology and Medicine*, *132*, 104335. https://doi.org/https://doi.org/10.1016/j.compbiomed.2021.104335

An, S., Teo, K., McConnell, M. V, Marshall, J., Galloway, C., & Squirrell, D. (2025). AI explainability in oculomics: How it works, its role in establishing trust, and what still needs to be addressed. *Progress in Retinal and Eye Research*, *106*, 101352. https://doi.org/https://doi.org/10.1016/j.preteyeres.2025.101352

Badhon, B., Chakrabortty, R. K., Anavatti, S. G., & Vanhoucke, M. (2025). IRAF-BRB: An explainable AI framework for enhanced interpretability in project risk assessment. *Expert Systems with Applications*, *285*, 127979. https://doi.org/https://doi.org/10.1016/j.eswa.2025.127979

Bhanothu, Y., Jawahar, M., & Prakash, J. S. (2024). Vision Based Leather Surface Defect Detection & Classification using Convolutional Neural Networks. *2024 10th International Conference on Advanced Computing and Communication Systems (ICACCS)*, *1*, 989–994. https://doi.org/10.1109/ICACCS60874.2024.10717129

Cao, L., Han, Q., Luo, R., Yang, L., Sun, Y., & Jia, W. (2025). Bilateral Triple-interaction network: An accurate segmentation model of wet-blue hide surface defects for leather industry. *Engineering Applications of Artificial Intelligence*, *153*, 110864. https://doi.org/https://doi.org/10.1016/j.engappai.2025.110864

Chen, W., Luo, X., & Zhu, X. (2025). A Defect Detection Method for Artificial Leather Based on YOLOv5. *2025 13th International Conference on Intelligent Control and Information Processing (ICICIP)*, 239–243. https://doi.org/10.1109/ICICIP64458.2025.10898103

Chen, Z., Zhu, Q., Zhou, X., Deng, J., & Song, W. (2024). Experimental Study on YOLO-Based Leather Surface Defect Detection. *IEEE Access*, *12*, 32830–32848. https://doi.org/10.1109/ACCESS.2024.3369705

Deperlioglu, O., Kose, U., Gupta, D., Khanna, A., Giampaolo, F., & Fortino, G. (2022). Explainable framework for Glaucoma diagnosis by image processing and convolutional neural network synergy: Analysis with doctor evaluation. *Future Generation Computer Systems*, *129*, 152–169. https://doi.org/https://doi.org/10.1016/j.future.2021.11.018

Frannita, E. L., & Prananda, A. R. (2024). Penerapan Metode CNN (Convolutional Neural Network) untuk Mengklasifikasikan Jenis Cacat pada Kulit Hewan. *TIN : Terapan Informatika Nusantara*, *5*(2), 125–134. https://doi.org/10.47065/tin.v5i2.5390

Gabeff, V., Teijeiro, T., Zapater, M., Cammoun, L., Rheims, S., Ryvlin, P., & Atienza, D. (2021). Interpreting deep learning models for epileptic seizure detection on EEG signals. *Artificial Intelligence in Medicine*, *117*, 102084. https://doi.org/https://doi.org/10.1016/j.artmed.2021.102084

He, X., Li, H., Liu, Y., Song, R., Zhao, Y., & Ou, X. (2024). Leather Defect Detection Algorithm Based on an Improved YOLOv5s. *2024 7th International Conference on Pattern Recognition and Artificial Intelligence (PRAI)*, 679–684. https://doi.org/10.1109/PRAI62207.2024.10826797

Hosain, M. T., Jim, J. R., Mridha, M. F., & Kabir, M. M. (2024). Explainable AI approaches in deep learning: Advancements, applications and challenges. *Computers and Electrical Engineering*, *117*, 109246. https://doi.org/https://doi.org/10.1016/j.compeleceng.2024.109246

Jin, X., & Lu, R. (2023). Triangle-based Defect Detection in Perforated Leather using YOLOv5. *2023 4th International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE)*, 266–272. https://doi.org/10.1109/ICBASE59196.2023.10303251

Mai, C., Penava, P., & Buettner, R. (2024). A Novel Deep Learning-Based Approach for Defect Detection of Synthetic

Copyright © 2025 the author, Page 121
This Journal is licensed under a Creative Commons Attribution 4.0 International License


TIN: Terapan Informatika Nusantara
Vol 6, No 2, July 2025, page 113-122
ISSN 2722-7987 (Media Online)
Website https://ejurnal.seminar-id.com/index.php/tin
DOI 10.47065/tin.v6i2.7425

Leather Using Gaussian Filtering. *IEEE Access*, *12*, 196702–196714. https://doi.org/10.1109/ACCESS.2024.3521497

Omoloso, O., Mortimer, K., Wise, W. R., & Jraisat, L. (2021). Sustainability research in the leather industry: A critical review of progress and opportunities for future research. *Journal of Cleaner Production*, *285*, 125441. https://doi.org/https://doi.org/10.1016/j.jclepro.2020.125441

Prananda, A., & Frannita, E. (2023). Toward Adaptive Manufacturing Development: Implementation of Artificial Intelligence for Identifying Leather Defects. *Jurnal Ecotipe (Electronic, Control, Telecommunication, Information, and Power Engineering)*, *10*(2 SE-Articles). https://doi.org/10.33019/jurnalecotipe.v10i2.4329

Prananda, A. R., & Frannita, E. L. (2023a). Toward Adaptive Manufacturing Development: Implementation of Artificial Intelligence for Identifying Leather Defects. *Jurnal Ecotipe (Electronic, Control, Telecommunication, Information, and Power Engineering)*, *10*(2), 200–207. https://doi.org/10.33019/jurnalecotipe.v10i2.4329

Prananda, A. R., & Frannita, E. L. (2023b). Toward Better Analysis of Breast Cancer Diagnosis: Interpretable AI for Breast Cancer Classification. *IT Journal Research and Development*, *7*(2), 220–227. https://doi.org/10.25299/itjrd.2023.11563

Prananda, A. R., & Frannita, E. L. (2024a). Klasifikasi Jenis Cacat pada Kulit Menggunakan Arsitektur GoogLeNet. *Pseudocode*, *11*(1), 15–20. https://doi.org/10.33369/pseudocode.11.1.15-20

Prananda, A. R., & Frannita, E. L. (2024b). Klasifikasi Jenis Cacat pada Kulit Menggunakan Arsitektur SMOTE-GoogLeNet. *JITU : Journal Informatic Technology And Communication*, *8*(1), 23–32. https://doi.org/10.33369/pseudocode.11.1.15-20

Raees, M., Meijerink, I., Lykourentzou, I., Khan, V.-J., & Papangelis, K. (2024). From explainable to interactive AI: A literature review on current trends in human-AI interaction. *International Journal of Human-Computer Studies*, *189*, 103301. https://doi.org/https://doi.org/10.1016/j.ijhcs.2024.103301

Samek, W., Montavon, G., Lapuschkin, S., Anders, C. J., & Müller, K.-R. (2021). Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications. *Proceedings of the IEEE*, *109*(3), 247–278. https://doi.org/10.1109/JPROC.2021.3060483

Setzu, M., Guidotti, R., Monreale, A., Turini, F., Pedreschi, D., & Giannotti, F. (2021). GLocalX - From Local to Global Explanations of Black Box AI Models. *Artificial Intelligence*, *294*, 103457. https://doi.org/https://doi.org/10.1016/j.artint.2021.103457

Wang, M., Qiu, H., Xiao, D., & Li, J. (2024). GND-YOLOv7 Based Leather Defect Detection Algorithm Research. *2024 5th International Seminar on Artificial Intelligence, Networking and Information Technology (AINIT)*, 718–721. https://doi.org/10.1109/AINIT61980.2024.10581626

Xu, Y., Yi, J., & Gao, J. (2023). Defect detection of automotive leather based on Nanodet-Plus. *2023 35th Chinese Control and Decision Conference (CCDC)*, 1458–1463. https://doi.org/10.1109/CCDC58219.2023.10326932

Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning Transferable Architectures for Scalable Image Recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 8697–8710. https://doi.org/10.1109/CVPR.2018.00907

This Journal is licensed under a Creative Commons Attribution 4.0 International License