

Klasifikasi Jenis Cacat pada Kulit Menggunakan Arsitektur GoogLeNet

Alifia Revan Prananda^a, Eka Legya Frannita^{b,*}

^aProgram Studi Teknologi Informasi, Fakultas Teknik, Universitas Tidar, Magelang, Indonesia

^bProgram Studi Teknologi Pengolahan Produk Kulit, Politeknik ATK Yogyakarta, Yogyakarta, Indonesia

Informasi Naskah:

Diterima: 31 Januari 2024/ Direview: 15 Februari 2024/ Direvisi: 22 Februari 2024/ Disetujui Terbit: 23 Februari 2024

DOI: 10.33369/pseudocode.11.1.15-20

*Korespondensi: eka.legya@atk.ac.id

Abstract

Deep learning has been proven to be able to provide significant contributions to several fields, including industry. It has also been proven that it has resulted in an outstanding performance for classification, detection, and even segmentation processes. In the leather industry, it also successfully gave valuable results, especially for the leather defect inspection process. This study aims to develop deep learning architecture for classifying leather defect. We used 3600 leather digital images distributed in six types of leather defects. In this study we employed GoogLeNet for classifying the data. Our experiment successfully achieved accuracy of 0.904 in training process and 0.885 in testing process. This result indicated that GoogLeNet provided powerful performance for classifying the type of leather defects.

Keywords: Leather, defect, classification, deep learning.

1. Pendahuluan

Pemanfaatan bahan kulit untuk menjadi produk fashion seperti tas, sepatu, busana, atau apparel yang lainnya telah diinisiasi sejak lima tahun yang lalu. Namun, pada saat itu pemanfaatan bahan kulit lebih banyak digunakan sebagai bahan dasar pembuatan busana untuk melindungi dari angin dan musim dingin. Pada era modern, bahan kulit telah berhasil dimanfaatkan secara lebih luas. Saat ini bahan kulit telah banyak dimanfaatkan untuk beberapa hal seperti sepatu, pakaian, furniture, aksesoris mobil, dan lain-lain [1].

Pembuatan kulit hingga menjadi produk siap pakai melalui beberapa tahapan pengolahan yang dimulai dari penyamakan kulit mentah hingga menjadi kulit tersamak yang siap untuk diolah menjadi produk siap pakai seperti busana kulit, tas kulit, sepatu kulit, dan aksesoris lainnya. Dari serangkaian tahap pengolahan kulit terdapat satu tahapan yang sangat esensial. Tahapan tersebut adalah tahap pengujian mutu kulit atau yang biasa dikenal dengan istilah *leather inspection process*. Proses ini bertujuan untuk mengidentifikasi kualitas kulit dan menentukan *grade* dari kulit tersebut. *Grade* harus ditentukan karena dalam pembuatan produk kulit, *grade* akan mempengaruhi kualitas produk yang dihasilkan dan tentunya akan mempengaruhi harga jual produk yang dihasilkan [2] [3].

Dalam proses pengujian kulit, dilakukan beberapa tahapan penting meliputi tahap pengukuran luas kulit, tahap identifikasi cacat kulit dan tahap pengukuran luas cacat kulit. Dari ketiga tahapan tersebut, tahapan identifikasi cacat kulit merupakan tahap yang paling susah. Hal ini dikarenakan cacat pada kulit sangat sukar untuk dibedakan dengan kondisi normal. Terlebih lagi sampai saat ini ketiga tahapan tersebut masih dilakukan secara manual. Sehingga memerlukan keahlian khusus dan membutuhkan banyak waktu. Selain itu,

proses identifikasi yang dilakukan secara manual tentunya juga bersifat subjektif. Kesalahan atau perbedaan pendapat antar cross-checker juga dapat sering kali terjadi [3]–[5].

Permasalahan di atas tentunya memberikan dampak negative bagi perusahaan kulit. Dampak tersebut dapat berupa dampak material maupun non material. Menanggapi hal tersebut maka diperlukan suatu inovasi untuk dapat memperbaiki prosedur pemeriksaan kualitas kulit agar kerugian pada saat produksi dapat diminimalisir se-efisien mungkin [5].

Dalam era kontemporer, pemanfaatan teknologi pada berbagai bidang telah terbukti memberikan benefit yang luar biasa [6]. Hal ini juga telah terbukti meningkatkan produktivitas diberbagai bidang. *Artificial intelligence*, sebagai salah satu teknologi mutakhir yang saat ini sedang berkembang pesat dan banyak dimanfaatkan untuk berbagai bidang ilmu [7]. Bidang industri kulit juga merupakan salah satu bidang ilmu yang mengimplementasikan *artificial intelligence* untuk berbagai kebutuhan [1], [8]–[12]. *Deep learning* merupakan salah satu teknologi *artificial intelligence* yang sangat populer dan memiliki kinerja yang sangat baik. *Deep learning* banyak digunakan untuk proses pendeteksian abnormalitas. *Deep learning* bahkan mampu mengekstrak data sekecil dan serumit mungkin untuk dapat diolah dan dijadikan informasi. Di beberapa kasus deep learning digunakan sebagai metode object detection yang sangat handal [13].

Melihat potensi deep learning yang luar biasa, maka penelitian ini mengusulkan penerapan *deep learning* untuk mengidentifikasi jenis-jenis cacat pada kulit. Adapun kontribusi yang ditawarkan dalam penelitian ini adalah penerapan metode *object classification* menggunakan arsitektur GoogLeNet untuk mengidentifikasi jenis cacat kulit. Arsitektur ini dipilih karena memiliki kompleksitas yang lebih rendah dibandingkan dengan arsitektur lain [14].

2. Related Work

Penelitian mengenai deteksi maupun klasifikasi pada pada kulit merupakan penelitian yang sudah banyak dilakukan mengingat pentingnya proses tersebut untuk mendukung proses produksi produk kulit. Dalam industri fashion, mengetahui informasi detail mengenai cacat pada kulit sebelum diolah menjadi suatu produk akan memberikan dampak yang sangat besar dalam meningkatkan profit perusahaan. Berikut adalah beberapa penelitian terdahulu tentang pemanfaatan kecerdasan buatan untuk mengidentifikasi cacat pada kulit. Penelitian yang dilakukan oleh Jawahar dkk [9] yang mengusulkan penerapan wavelet feature extraction untuk mengklasifikasikan cacat pada kulit. Penelitian ini menggunakan data gambar kulit digital sebanyak 700 gambar yang terdistribusi ke dalam dua kelas yakni defected sebanyak 500 gambar dan non-defected sebanyak 200 gambar. Penelitian ini menggunakan Wavelet Statistical Features (WSF) dan Wavelet Co-occurrence Features (WCF) serta kombinasi antara kedua untuk mengekstrak informasi dari data yang digunakan. Selanjutnya data diklasifikasikan menggunakan SVM. Eksperimen dalam penelitian ini memperoleh akurasi di atas 90% [9].

Penelitian yang diusulkan oleh Varghese dkk [15] tentang penerapan metode transfer learning untuk mengidentifikasi jenis spesies dari kulit yang dianalisis. Penelitian ini mendapatkan akurasi di atas 90% dalam mengklasifikasi jenis spesies hewan berdasarkan kondisi kulit yang diamati. Penelitian yang dilakukan oleh Bong dkk [10] tentang pemanfaatan computer vision dalam proses inspeksi atau pengecekan kualitas kulit. Penelitian ini menggunakan fitur warna, Zernike moments, fitur tekstur untuk mengekstrak informasi dari data. Selanjutnya, dilakukan klasifikasi menggunakan SVM. Adapun jenis cacat yang diidentifikasi dalam penelitian ini adalah *scars*, *scratches*, *pinholes*, dan *no-defects*. Eksperimen dalam penelitian ini berhasil memperoleh rata-rata akurasi di atas 90%.

Penelitian yang dilakukan oleh Vasagam dkk [16] tentang penerapan histogram equalization dalam proses klasifikasi jenis-jenis cacat pada kulit. Penelitian ini menerapkan beberapa jenis kulit seperti kulit sapi, domba dan kambing. Data kulit dalam bentuk gambar digital selanjutnya diekstrak menggunakan metode structural similarity index (SSIM) dan diklasifikasikan menggunakan metode naïve bayes. Eksperimen dalam penelitian ini berhasil memperoleh akurasi sebesar 94%. Penelitian yang dilakukan oleh Varghese dkk [17] tentang penerapan deep learning model untuk mengklasifikasikan sepsis hewan berdasarkan kondisi kulit yang diamati. Adapun beberapa arsitektur yang digunakan dalam penelitian ini antara lain ResNet50, MobileNet, DenseNet201, InceptionNetV3, dan InceptionResNetV2. Penelitian ini menggunakan 7600 dataset. Akurasi tertinggi yang diperoleh oleh penelitian ini adalah sebesar 94,07%. Penelitian yang diusulkan oleh Aslam dkk [18] tentang penerapan ensemble CNN untuk mengklasifikasi cacat kulit sesuai dengan kondisi di industri. Penelitian ini menggunakan jenis kulit wet-blue dan menggunakan arsitektur EfficientNet-B3+ ResNext-101 yang merupakan arsitektur baru memodifikasi dari arsitektur terdahulu.

Penelitian yang diusulkan oleh Varghese dkk [19] tentang pemanfaatan texture feature untuk mengklasifikasikan jenis spesies hewan berdasarkan kondisi kulit. Penelitian ini menggunakan *multi-resolution discrete wavelet transform* (DWT) dan *local binary pattern* (LBP) dalam proses ekstraksi fitur dan menggunakan MLP sebagai classifier untuk mengklasifikasikan data. Penelitian ini memperoleh akurasi sebesar 99,58%. Penelitian yang diusulkan oleh Deng dkk [20] tentang penggunaan *Optimized Residual Network* untuk mengklasifikasikan cacat kulit. Penelitian ini memperoleh akurasi sebesar 94,6%. Penelitian yang diusulkan oleh Jian dkk [21] tentang penerapan neural network dan decision tree untuk mengklasifikasikan cacat kulit. Penelitian ini berhasil memperoleh akurasi sebesar 94,9%.

Penelitian yang diusulkan oleh Pereira dkk [22] tentang penggunaan *computer vision* dan *machine learning* untuk mengklasifikasikan cacat pada kulit domba. Penelitian ini menggunakan beberapa fitur seperti *Gray Level Co-occurrence Matrix* (GLCM), *Local Binary Patterns* (LBP) and *Structural Co-occurrence Matrix* (SCM) pada proses ekstraksi fitur. Selanjutnya, hasil ekstraksi fitur diklasifikasikan dengan menggunakan beberapa classifier seperti *k-Nearest Neighbors* (KNN), *Multi-Layer Perceptron* (MLP) dan Support Vector Machine (SVM). Akurasi tertinggi diperoleh sebesar 90% dengan menggunakan MLP.

Sampaio dkk [23] mengusulkan penelitian tentang pemanfaatan embedded classifier untuk menentukan kualitas kulit. Adapun fitur yang digunakan dalam penelitian ini adalah fitur *Gray Level Co-occurrence Matrix* (GLCM) dan berhasil mendapatkan akurasi sebesar 90%. Penelitian yang diusulkan oleh Wang dkk [24] tentang TDENet untuk mengidentifikasi cacat pada kulit. Eksperimen dalam penelitian ini berhasil memperoleh akurasi di atas 90%.

Penelitian-penelitian di atas menunjukkan bahwa pemanfaatan artificial intelligence memiliki peluang yang sangat besar untuk digunakan dalam mendeteksi jenis-jenis cacat pada kulit. Namun, hampir keseluruhan dari penelitian di atas hanya melibatkan Sebagian kecil dari jenis-jenis cacat kulit yang ditemukan terutama pada industri dan pada saat proses produksi berlangsung. Penelitian ini menyajikan eksperimen tentang pemanfaatan arsitektur deep learning untuk mengidentifikasi jenis-jenis cacat kulit. Adapun jenis cacat kulit yang digunakan dalam penelitian ini antara lain *folding marks*, *grain off*, *growth marks*, *loose grains*, dan *pinhole* yang merupakan jenis-jenis cacat yang sering ditemui.

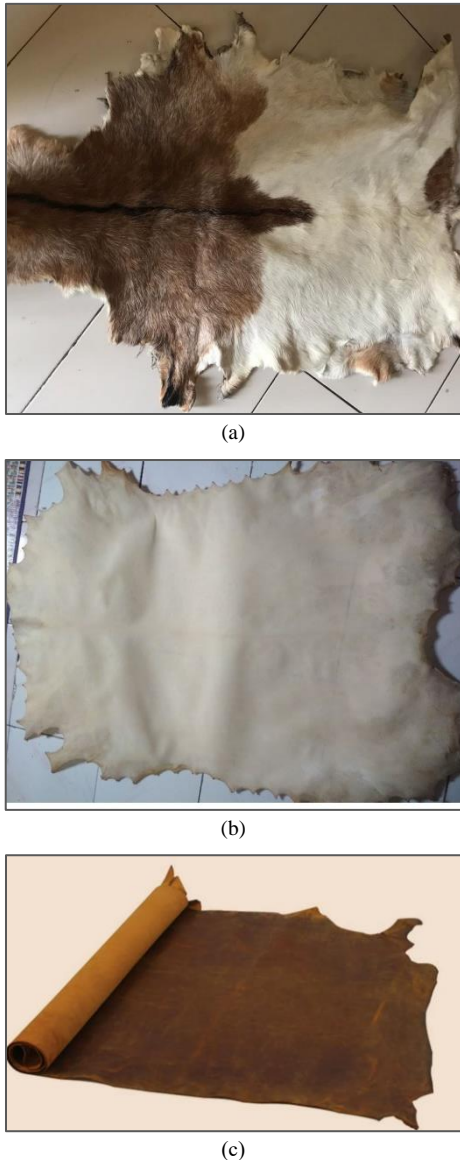
3. Metodologi Penelitian

Penelitian ini bertujuan mengembangkan metode yang mampu mengidentifikasi jenis cacat pada kulit menggunakan arsitektur GoogLeNet. Adapun data yang digunakan dalam penelitian ini adalah data citra digital kulit tersamak sejumlah 3600 citra yang didistribusikan ke dalam enam kelas. Adapun deskripsi dari data yang digunakan dan arsitektur yang diaplikasikan dijelaskan pada sub-bab berikut.

3.1. Deskripsi data

Data yang digunakan pada penelitian ini berbentuk citra digital kulit tersamak. Kulit tersamak adalah kulit yang telah


melalui tahap pengolahan atau penyamakan kulit dan siap untuk diolah menjadi produk seperti tas, sepatu atau busana. Contoh perbedaan kulit hewan dengan kulit tersamak dapat dilihat pada Gambar 1. Namun, pada penelitian ini, data yang digunakan adalah region of interest atau RoI yang hanya fokus pada cacat-cacat atau defek-defek pada kulit. Contoh data dapat dilihat pada Gambar 2. Data terdiri atas 3600 citra yang terdiri atas enam kelas. Adapun rincian deskripsi data dapat dilihat pada Tabel 1.



Gambar 1. Ilustrasi pengolahan kulit: (a) kulit hewan (kambing/domba) yang masih berbulu, (b) kulit hewan yang sudah melalui proses pengolahan atau penyamakan (pada bagian ini disebut kulit pikel), (c) kulit tersamak atau kulit jadi yang siap digunakan untuk membuat tas, sepatu atau busana.

Dalam penelitian ini terdapat enam kelas yang digunakan. Keenam kelas tersebut antara lain *folding mask*, *grain off*, *growth marks*, *loose grains*, *pinhole*, *non-defective*. Keenam kelas tersebut merupakan jenis-jenis cacat yang sering muncul pada saat pemeriksaan kualitas kulit. Keenam jenis cacat ini berkaitan dengan tekstur kulit yang kurang harus akibat beberapa hal misalnya karena proses penyamakan yang kurang baik, adanya luka atau bekas luka pada hewan, adanya kerutan dan sebagainya. Gambar 2(f) menunjukkan kulit

yang memiliki permukaan halus dan tidak terdapat cacat.



Gambar 2. Contoh citra kulit tersamak: (a) *folding marks*, (b) *grain off*, (c) *growth marks*, (d) *loose grains*, (e) *pinhole* dan (f) *non-defective*.

Untuk mempermudah memberikan gambaran mengenai data yang digunakan dalam penelitian ini, berikut adalah ringkasan dari data yang digunakan yang berisi deskripsi dari data. Dalam tabel berikut dijelaskan jenis data, dimensi, proporsi data *ground truth* atau referensi data, dan sumber data.

Tabel 1. Deskripsi dataset yang digunakan

Komponen	Deskripsi
Jenis citra	Digital leather defect images
Dimensi	227 x 227 piksel
Ground truth	Klasifikasi yang terdiri dari enam kelas yakni <i>folding marks</i> , <i>grain off</i> , <i>growth marks</i> , <i>loose grains</i> , <i>pinhole</i> dan <i>non-defective</i> .
Jumlah data	Dataset terdiri atas 3600 citra yang terdistribusi dalam proporsi berikut: <ol style="list-style-type: none"> <i>folding marks</i>: 600 gambar <i>grain off</i>: 600 gambar <i>growth marks</i>: 600 gambar <i>loose grains</i>: 600 gambar <i>pinhole</i>: 600 gambar <i>non-defective</i>: 600 gambar
Sumber data	Dataset yang digunakan merupakan public dataset dari penelitian yang dilakukan oleh Vasagam dkk [5]

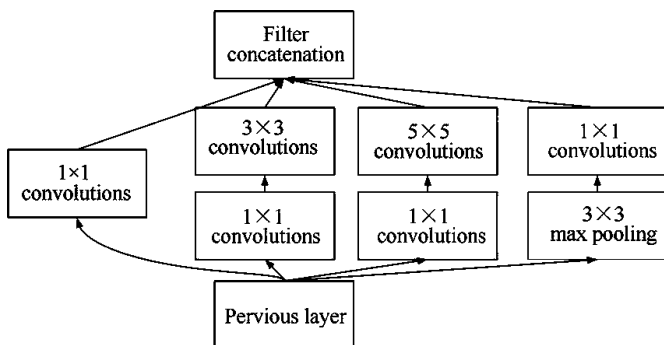
3.2. Arsitektur deep learning

Penelitian ini menggunakan arsitektur GoogLeNet secara default tanpa ada modifikasi pada arsitektur yang digunakan untuk untuk mengklasifikasikan data menjadi enam kelas [25]. Berikut adalah arsitektur yang digunakan dalam penelitian ini:

Tabel 2. Struktur arsitektur GoogLeNet

Type of layer	Patch size/stride	Output size	Depth	Parameters
Convolution	7×7/2	112×112×64	1	2.7K
Max pool	3×3/2	56×56×64	0	
Convolution	3×3/1	56×56×192	2	112K
Max pool	3×3/2	28×28×192	0	
Inception (3a)		28×28×256	2	159K
Inception (3b)		28×28×480	2	380K
Max pool	3×3/2	14×14×480	0	
Inception (4a)		14×14×512	2	364K
Inception (4b)		14×14×512	2	437K
Inception (4c)		14×14×512	2	463K
Inception (4d)		14×14×528	2	580K
Inception (4e)		14×14×832	2	840K
Max pool	3×3/2	7×7×832	0	
Inception (5a)		7×7×832	2	1072K
Inception (5b)		7×7×1024	2	1388K
Avg pool	7×7/1	1×1×1024	0	
Dropout (40%)		1×1×1024	0	
Linear		1×1×1024	1	1000K
Softmax		1×1×1024	0	

Arsitektur GoogLeNet mencakup beberapa modul awal yang ditumpuk bersama-sama, sehingga menghasilkan jaringan dengan kedalaman dan akurasi yang lebih baik. Modul ini disebut sebagai *inspection* modul seperti yang diilustrasikan pada Gambar 3. Selain itu, para peneliti memperkenalkan pengklasifikasi tambahan pada lapisan perantara, yang membantu mengatasi masalah hilangnya *gradient* selama pelatihan. Setiap *inception* berfungsi untuk mengurangi biaya komputasi dengan memanfaatkan konvolusi 1x1 untuk melakukan pengurangan dimensi sebelum menerapkan kernel konvolusional yang lebih besar. Hal ini tidak hanya menghemat komputasi tetapi juga bertindak sebagai pengatur, mencegah *overfitting*.



Gambar 3. Modul inspection [7].

Hasil dan Pembahasan

4.1. Hasil proses *training* dan *testing*

Penelitian ini bertujuan untuk mengembangkan arsitektur deep learning guna untuk mengklasifikasikan data cacat kulit kedalam enam kelas. Adapun cacat kulit tersebut sangat perlu untuk diidentifikasi sejak dini agar tidak mengurangi harga jual dari kulit yang diolah. Dalam proses klasifikasi data penelitian ini menggunakan arsitektur GoogLeNet. Sebelum melakukan proses *training*, dilakukan proses pembagian proporsi data.

Adapun proposi data dalam penelitian ini adalah 80:10:10 yang mana terdiri dari data *training* data *validation* dan data *testing*. Kemudian dilakukan proses *training* pada beberapa setting jumlah epoch, batch size dan mini batch size. Hal ini diperlukan untuk menentukan pengaturan mana yang paling tepat. Berikut adalah hasil dari eksperimen yang telah dilakukan:

Tabel 3. Rekap hasil *training* dan *testing*

Komponen	Hasil	
Ukuran data	227×227	
Proporsi data	80:10:10	
Jumlah parameter	1.254.076	
Batch size	8	
Mini batch size	16	
Jumlah epoch	125	
Hasil pada proses pelatihan	Accuracy	0,904
	Precision	0,916
	Recall	0,904
	F1-score	0,905
	ROC	0,992
Hasil pada proses pengujian	Accuracy	0,885
	Precision	0,922
	Recall	0,885
	F1-score	0,882
	ROC	0,991

Confusion matrix dari proses pelatihan dan pengujian dapat dilihat pada Gambar 4 dan 5 sebagai berikut:

a	b	c	d	e	f	← Classified as		
435	33	0	2	0	10	a	:	Folding marks
81	408	0	1	0	0	b	:	Grain off
0	1	479	0	0	0	c	:	Growth marks
0	0	0	480	0	0	d	:	Loose grains
0	3	1	2	479	0	e	:	Non-defective
87	56	0	0	0	337	f	:	Pinhole

Gambar 4. *Confusion matrix* pada proses *training*

a	b	c	d	e	f	← Classified as		
61	59	0	2	0	10	a	:	Folding marks
0	120	0	1	0	0	b	:	Grain off
0	0	115	0	0	0	c	:	Growth marks
0	0	0	115	0	0	d	:	Loose grains
0	0	0	1	119	0	e	:	Non-defective
0	13	0	0	0	107	f	:	Pinhole

Gambar. 5. Confusion matrix pada proses testing

4.2. Pembahasan

Hasil pada Tabel 3 dan Gambar 4 dan 5 menunjukkan performa atau kinerja dari GoogLeNet dalam mengklasifikasikan data kedalam enam kelas yakni *folding marks*, *grain off*, *growth marks*, *loose grains*, *pinhole* dan *non-defective*. Berdasarkan akurasi yang disajikan pada proses training dan testing menunjukkan bahwa arsitektur GoogLeNet memiliki performa yang baik dalam mengklasifikasikan data yang mana terbukti dari nilai akurasi *training* dan *testing* yang tinggi. Namun, berdasarkan *confusion matrix* yang disajikan pada Gambar 3 dan Gambar 4 terdapat jenis cacat yang cukup sulit diidentifikasi oleh arsitektur GoogLeNet. Jenis cacat tersebut adalah *folding marks*. Hal ini dikarenakan jenis *folding marks* dan *grain off* memiliki karakteristik yang hampir sama. *Pinhole* juga salah satu jenis cacat yang sulit untuk dideteksi. Hal ini terlihat pada Gambar 3 dan Gambar 4 terdapat beberapa data *pinhole* yang diklasifikasikan pada kelas yang salah. Sama seperti *folding mask*, *pinhole* memiliki karakteristik yang hampir mirip dengan *grain off* dan *folding mask* sehingga sering kali diklasifikasikan ke menjadi *grain off* dan *folding mask*. Namun dengan performa yang diperoleh telah menunjukkan bahwa metode yang diangkat memiliki performa yang naik dalam mengklasifikasikan data.

Disisi lain, penggunaan dataset telah digunakan oleh beberapa peneliti sebelumnya seperti penelitian yang dilakukan oleh Vasagam dkk tentang penerapan *black hat transform* dan *Hough transform* untuk mendeteksi cacat kulit. Dengan data yang sama penelitian ini berhasil mendapatkan akurasi sebesar 94%. Pada penelitian ini digunakan beberapa metode konvensional seperti *image enhancement*, *feature extraction* dan *classification*, sehingga walaupun menghasilkan akurasi yang tinggi namun memiliki kompleksitas dan *running time* yang tinggi. Penelitian lain yang dilakukan oleh Praveen dkk telah berhasil mengembangkan model *deep learning* dengan arsitektur AlexNet dan memperoleh akurasi *training* sebesar 99.40% dan akurasi *testing* sebesar 87.60% [26]. Hasil tersebut menunjukkan hasil yang hampir sama dengan hasil yang diperoleh dari penelitian yang diusulkan.

Kesimpulan

Penelitian ini bertujuan untuk mengembangkan arsitektur *deep learning* menggunakan arsitektur GoogLeNet untuk mengklasifikasikan data jenis cacat kulit ke dalam enam kelas yakni *folding marks*, *grain off*, *growth marks*, *loose grains*, *pinhole* dan *non-defective*. Penelitian ini menggunakan data citra kulit digital sebanyak 3600 citra yang didistribusikan ke dalam enam kelas dengan proporsi masing-masing kelas sebanyak 600 citra. Penelitian ini menggunakan ukuran *batch size* sebesar 8 dan *mini batch size* sebesar 16 yang dijalankan selama 125 epoch. Jumlah ini diambil karena pada epoch tersebut akurasi sudah mencapai titik konvergen. Sebelum proses *training* data dibagi terlebih dahulu untuk kebutuhan *training*, *validation* dan *testing* dengan proporsi 80:10:10. Hasil *training* dari eksperimen yang dilakukan mencapai akurasi sebesar 0,904. Sedangkan hasil akurasi pada saat proses *testing* sebesar 0,885. Hasil ini merupakan hasil yang sangat baik untuk dapat digunakan lebih lanjut dalam mendeteksi jenis-jenis cacat kulit. Dalam pengembangan lebih lanjut, hasil dari penelitian ini dapat digunakan sebagai bagian dari pengembangan *automated leather inspection system* yang mempermudah proses pengujian mutu kulit di industri. Dengan temuan-temuan semacam ini, maka proses pengujian kualitas kulit dapat dilakukan lebih cepat dan lebih efisien.

Referensi

- [1] S. Liang, Y. Gan, Y.-C. Huang, C.-A. Yuan, and H.-C. Chang, "Automatic Defect Segmentation on Leather with Deep Learning," *arXiv*, Mar. 2019, doi: <https://doi.org/10.48550/arXiv.1903.12139>.
- [2] S.-T. Liang, D. Zheng, Y.-C. Huang, and Y. S. Gan, "Leather defect classification and segmentation using deep learning architecture," *Int. J. Comput. Integr. Manuf.*, vol. 33, no. 10–11, pp. 1105–1117, Nov. 2020, doi: [10.1080/0951192X.2020.1795928](https://doi.org/10.1080/0951192X.2020.1795928).
- [3] M. Rossi, A. Papetti, M. Marconi, and M. Germani, "Life cycle assessment of a leather shoe supply chain," *Int. J. Sustain. Eng.*, vol. 14, no. 4, pp. 686–703, 2021, doi: [10.1080/19397038.2021.1920643](https://doi.org/10.1080/19397038.2021.1920643).
- [4] Y. Kroutchinin and L.-A. Baudrier, "The life cycle of footwear production," Paris, 2013.
- [5] S. N. Vasagam and M. Sornam, "Intermittent Leather Defect Detection Based on Ensemble Algorithms Derived from Black Hat Transformation and Hough Transformation BT - ICT Analysis and Applications," 2022, pp. 35–45.
- [6] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2818–2826. doi: [10.1109/CVPR.2016.308](https://doi.org/10.1109/CVPR.2016.308).
- [7] C. Szegedy et al., "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1–9. doi: [10.1109/CVPR.2015.7298594](https://doi.org/10.1109/CVPR.2015.7298594).
- [8] S.-T. Liang, Y. S. Gan, Y.-C. Huang, K.-H. Liu, and W.-C. Yau, "Integrated Neural Network and Machine Vision Approach For Leather Defect Classification," 2019, [Online]. Available: <http://arxiv.org/abs/1905.11731>
- [9] M. Jawahar, N. K. C. Babu, and K. Vani, "Leather texture classification using wavelet feature extraction technique," in *2014 IEEE International Conference on Computational Intelligence and Computing Research*, 2014, pp. 1–4. doi: [10.1109/ICICR.2014.7000000](https://doi.org/10.1109/ICICR.2014.7000000).

- 10.1109/ICCIC.2014.7238475.
- [10] H.-Q. Bong, Q.-B. Truong, H.-C. Nguyen, and M.-T. Nguyen, "Vision-based Inspection System for Leather Surface Defect Detection and Classification," in *2018 5th NAFOSTED Conference on Information and Computer Science (NICS)*, 2018, pp. 300–304. doi: 10.1109/NICS.2018.8606836.
- [11] S. T. Liong, D. Zheng, Y. C. Huang, and Y. S. Gan, "Leather defect classification and segmentation using deep learning architecture," *Int. J. Comput. Integr. Manuf.*, vol. 33, no. 10–11, pp. 1105–1117, 2020, doi: 10.1080/0951192X.2020.1795928.
- [12] Y. S. Gan *et al.*, "Detection and localization of defects on natural leather surfaces," *J. Ambient Intell. Humaniz. Comput.*, vol. 14, no. 3, pp. 1785–1799, 2023, doi: 10.1007/s12652-021-03396-2.
- [13] S. Misra and S. Bera, "Introduction to Big Data Analytics," *Smart Grid Technol.*, no. July, pp. 38–48, 2018, doi: 10.1017/9781108566506.005.
- [14] S. Han *et al.*, "A deep learning framework for supporting the classification of breast lesions in ultrasound images," *Phys. Med. Biol.*, vol. 62, no. 19, pp. 7714–7728, 2017, doi: 10.1088/1361-6560/aa82ec.
- [15] A. Varghese, M. Jawahar, and A. A. Prince, "Transfer Learning-based Rich Feature Analysis on Leather Images for Species Prediction," in *2023 10th International Conference on Signal Processing and Integrated Networks (SPIN)*, 2023, pp. 301–305. doi: 10.1109/SPIN57001.2023.10117459.
- [16] Vasagam, S. N. Vasagam, and M. Sornam, "Species Wise Classification of Crust Leather images based on histogram equalization," in *2022 6th International Conference on Computing Methodologies and Communication (ICCMC)*, 2022, pp. 1307–1312. doi: 10.1109/ICCMC53470.2022.9753704.
- [17] A. Varghese, M. Jawahar, and A. A. Prince, "A Study on Deep Learning Models for Automatic Species Identification from Novel Leather Images," in *2023 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)*, 2023, pp. 25–30. doi: 10.1109/IAICT59002.2023.10205553.
- [18] M. Aslam, T. M. Khan, S. S. Naqvi, G. Holmes, and R. Naffa, "Ensemble Convolutional Neural Networks With Knowledge Transfer for Leather Defect Classification in Industrial Settings," *IEEE Access*, vol. 8, pp. 198600–198614, 2020, doi: 10.1109/ACCESS.2020.3034731.
- [19] A. Varghese, M. Jawahar, A. A. Prince, and A. H. Gandomi, "Texture Analysis on Digital Microscopic Leather Images For Species Identification," in *2022 9th International Conference on Soft Computing & Machine Intelligence (ISCMI)*, 2022, pp. 223–227. doi: 10.1109/ISCMI56532.2022.10068472.
- [20] J. Deng, J. Liu, C. Wu, T. Zhong, G. Gu, and B. W.-K. Ling, "A Novel Framework for Classifying Leather Surface Defects Based on a Parameter Optimized Residual Network," *IEEE Access*, vol. 8, pp. 192109–192118, 2020, doi: 10.1109/ACCESS.2020.3032164.
- [21] L. Jian, H. Wei, and H. Bin, "Research on inspection and classification of leather surface defects based on neural network and decision tree," in *2010 International Conference On Computer Design and Applications*, 2010, vol. 2, pp. V2-381-V2-384. doi: 10.1109/ICCD.2010.5541405.
- [22] R. F. Pereira, C. M. S. Medeiros, and P. P. R. Filho, "Goat Leather Quality Classification Using Computer Vision and Machine Learning," in *2018 International Joint Conference on Neural Networks (IJCNN)*, 2018, pp. 1–8. doi: 10.1109/IJCNN.2018.8489265.
- [23] F. Sampaio, L. C. da Silva, P. P. R. Filho, and E. T. Silva, "Reducing Computational Costs of an Embedded Classifier to Determine Leather Quality," in *2017 VII Brazilian Symposium on Computing Systems Engineering (SBESC)*, 2017, pp. 211–216. doi: 10.1109/SBESC.2017.36.
- [24] F. Wang and K. J. Kyoung, "Leather Defect Detection Method in Clothing Design Based on TDENet," *IEEE Access*, vol. 11, pp. 104890–104904, 2023, doi: 10.1109/ACCESS.2023.3308493.
- [25] E. Gomedé, "Exploring GoogLeNet: A Revolutionary Deep Learning Architecture," 2023. <https://medium.com/@evertongomede/exploring-googlenet-a-revolutionary-deep-learning-architecture-8bb176a0facc> (accessed Jan. 15, 2023).
- [26] P. K. Moganam and D. A. Sathia Seelan, "Deep learning and machine learning neural network approaches for multi class leather texture defect classification and segmentation," *J. Leather Sci. Eng.*, vol. 4, no. 1, p. 7, 2022, doi: 10.1186/s42825-022-00080-9.