

# Klasifikasi Jenis Cacat Kulit Menggunakan SMOTE-GoogLeNet

Alifia Revan Prananda<sup>a,1</sup>, Eka Legya Frannita<sup>b,2,\*</sup>, Erlita Pramitaningrum<sup>b,3</sup>, Anwar Hidayat<sup>b,4</sup>,  
Wawan Budi Setiawan<sup>b,5</sup>, Nunik Purwaningsih<sup>b,6</sup>

<sup>a</sup> Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Tidar, Magelang 56116, Indonesia

<sup>b</sup> Program Studi Teknologi Pengolahan Produk Kulit, Politeknik ATK Yogyakarta, Yogyakarta 55188, Indonesia

<sup>1</sup> revan@untidar.ac.id; <sup>2</sup> eka.legya@atk.ac.id \*; <sup>3</sup> erlita.pramitaningrum@atk.ac.id; <sup>4</sup> anwar@atk.ac.id; <sup>5</sup> wbsetiawan@atk.ac.id; <sup>6</sup> nunik@atk.ac.id;

\* Korespondensi penulis

Naskah Menerima 26/4/2024, Revisi 22/5/2024, Diterima 29/5/2024

## 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. However, despite its outstanding performance, it remained a drawback because it produced insignificant results if employed in a small or imbalanced dataset. This research work focuses on the analysis of the implementation of the data balancing method for improving the performance of the deep learning method for classifying the types of leather defects. This research work was done by employing two processes. In the first step, we utilized the data balancing method to balance the data proportion. In the next step, we employed GoogLeNet as a deep learning architecture for training and testing processes. Our experiment was conducted in two scenarios. The first scenario was done by using the original dataset. Whereas the second scenario was accomplished by utilizing the data balancing method before training and testing. According to the experiment results, implementing the data balancing method successfully increased the performance of the deep learning method by more than 15%. It can be inferred that the proportion or the number of data strongly affected the performance of deep learning models.*

*Keywords: classification, data balancing method, deep learning, GoogLeNet, leather defect*

## Abstrak

Deep Learning telah terbukti dapat memberikan kontribusi yang signifikan pada berbagai bidang, termasuk di bidang industri. Deep learning juga telah terbukti memberikan hasil yang sangat baik untuk klasifikasi, deteksi, bahkan proses segmentasi. Dalam industri kulit, deep learning juga telah sukses memberikan hasil yang berharga, utamanya pada proses inspeksi cacat kulit. Meskipun demikian, masih terdapat kekurangan yaitu masih memberikan hasil yang kurang baik ketika dibuat menggunakan dataset yang sedikit atau tidak seimbang. Penelitian ini berfokus pada analisis penerapan data balancing method untuk meningkatkan performa dari metode deep learning dalam klasifikasi jenis cacat kulit. Penelitian ini dilakukan dengan menggunakan dua langkah. Langkah pertama, dilakukan data balancing method untuk menyeimbangkan proporsi data. Langkah selanjutnya, penelitian ini menggunakan GoogLeNet sebagai arsitektur deep learning untuk proses training dan testing. Eksperimen ini dilakukan menggunakan dua skenario. Skenario pertama dilakukan menggunakan dataset original. Sementara skenario kedua dilakukan menggunakan data balancing method sebelum proses training dan testing dilakukan. Berdasarkan hasil eksperimen, implementasi dari data balancing method berhasil meningkatkan performa deep learning hingga lebih dari 15%. Berdasarkan hal tersebut, dapat disimpulkan bahwa proporsi dari jumlah data sangat berpengaruh terhadap performa dari model deep learning.

Kata kunci: klasifikasi, data balancing method, deep learning, GoogLeNet, cacat kulit

*This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.*



## 1. Pendahuluan

Penggunaan bahan kulit telah dimulai sejak lima ribu tahun yang lalu. Pada generasi tersebut orang mulai menggunakan pakaian kulit untuk melindungi diri dari angin dan dingin. Di pertengahan abad ke dua puluh, dengan meningkatnya kesejahteraan dan perkembangan berbagai sumber daya diiringi dengan berkembangnya inovasi teknologi dimana saat sudah mulai memasuki era digitalisasi, banyak negara secara bertahap membentuk sistem pemrosesan kulit yang lebih besar di industri penyamakan kulit. Sejak saat itu, kulit menjadi material eksterior yang populer di berbagai aplikasi, seperti sepatu, pakaian, furniture, aksesoris mobil, dan lain-lain [1][2].

Perkembangan fashion dengan bahan dasar kulit saat ini telah mengalami berbagai macam perubahan dan perkembangan. Proses tersebut dipengaruhi oleh berbagai macam hal seperti adanya inovasi desain. Seiring dengan perkembangan jaman, pola desain juga ikut berkembang baik dari sisi permainan warna, modifikasi pola hingga tekstur. Hal ini juga mempengaruhi tren fashion dengan bahan dasar kulit yang juga ikut semakin berkembang luas. Selain adanya fenomena tren yang semakin berkembang, dukungan teknologi mutakhir juga menjadi salah satu factor yang sangat mempengaruhi proses perkembangan fashion. Dalam fashion dengan bahan dasar kulit, dukungan teknologi sangat memberikan dampak positif untuk proses bisnis pembuatan produk. Dengan adanya teknologi, proses pembuatan produk menjadi lebih efektif dan efisien. Beberapa factor tersebut pada akhirnya mempengaruhi proses perkembangannya life style masyarakat luas [3].

Proses pengolahan kulit hingga menjadi komoditas material eksterior mencakup beberapa proses dari kulit mentah hingga menjadi kulit. Kulit merupakan kulit matang yang sudah siap untuk diolah menjadi suatu produk seperti busana, sepatu, tas hingga aksesoris yang lain. Proses pengolahan ini pada dasarnya mencakup beberapa tahap antara lain pembuatan raw material, proses penyamakan, proses uji kualitas kulit, proses produksi. Setiap proses memiliki peran yang sangat penting. Namun, penelitian ini fokus pada proses uji kualitas kulit. Hal ini dikarenakan untuk proses-proses yang lain sudah banyak didukung dengan alat-alat otomatis. Sedangkan untuk proses uji kualitas kulit masih menggunakan cara tradisional. Saat ini, proses uji kualitas kulit dilakukan dengan cara pengamatan secara langsung oleh ahli-ahli atau orang dengan pengalaman yang cukup lama. Hal yang diamati antara lain adalah luas kulit, jumlah cacat, jenis cacat, dan luas cacat. Hasil uji kualitas kulit ini nantinya akan menentukan jenis artikel atau produk yang tepat untuk kulit tersebut. Sebagai contoh misal kulit dengan luas bersih (luas tanpa cacat) 5 feet maka hanya bisa digunakan untuk produk seperti tas. Untuk kulit dengan luas bersih 3 feet maka hanya bisa digunakan untuk produk-produk berukuran kecil seperti dompet, clutch dan sebagainya [2].

Dari proses uji kualitas kulit ini, proses mengidentifikasi jenis cacat kulit merupakan proses yang paling beresiko karena membutuhkan ketelitian, pengalaman dan waktu yang cukup lama. Bahkan di beberapa negara, untuk dapat menguji kualitas kulit diperlukan sertifikat keahlian tersebut. Sehingga dapat disimpulkan bahwa proses tersebut merupakan proses yang sangat penting, sebab jika terjadi kesalahan dalam mengenali cacat pada kulit maka kulit tidak dapat digunakan untuk membuat produk. Akibatnya, hal tersebut akan merugikan perusahaan. Melihat hal tersebut, proses uji kualitas kulit yang dilakukan dengan cara manual tentunya dapat mengurangi efektivitas dan efisiensi dimana proses yang masih dilakukan secara manual tentunya membutuhkan waktu yang lebih lama dan memerlukan keahlian. Di samping itu, proses yang manual juga beresiko memberikan hasil yang subjektif karena hasil pemeriksaan yang manual sangat tergantung terhadap kemampuan dan pengalaman pemeriksa. Perbedaan pendapat antar pemeriksa atau evaluator juga mungkin terjadi [4][5].

Menanggapi permasalahan tersebut, maka diperlukan suatu metode alternatif yang dapat mengidentifikasi cacat kulit secara lebih objektif. Dalam beberapa tahun terakhir, kemajuan artificial intelligence (AI) telah berhasil menunjukkan penerapan praktisnya dalam melakukan deteksi secara visual di berbagai sektor industri. AI juga terbukti mampu memberikan hasil yang sangat signifikan dalam melakukan deteksi maupun klasifikasi objek [6][7][8]. Artificial intelligence merupakan teknologi mutakhir yang terbukti memberikan performa luar biasa di berbagai kasus. Beberapa tahun terakhir, object detection and classification merupakan pendekatan populer yang sering dimanfaatkan peneliti untuk menyelesaikan berbagai kasus. Penelitian ini mengusulkan penggunaan metode deep learning untuk mengidentifikasi jenis-jenis cacat pada kulit. Deep learning bekerja dengan cara mengekstrak ciri dari citra digital yang diinputkan ke dalam model dan menganalisis ciri tersebut guna melakukan identifikasi jenis kelas dari objek yang dikenali. Deep learning sangat efektif untuk mengekstrak data dengan fitur yang kompleks. Deep learning juga sangat handal untuk mengekstrak data dalam jumlah besar. Melihat karakteristik dan prinsip kerja deep learning, metode ini sangat cocok dikembangkan pada kasus yang diusulkan. Hal tersebut dikarenakan jenis cacat pada kulit memiliki ciri atau fitur yang kompleks. Untuk dapat mengenali karakteristik yang kompleks tersebut diperlukan metode yang handal agar kesalahan deteksi dapat diminimalisir sekecil mungkin. Sehingga, metode deep learning memiliki potensi yang sangat besar untuk digunakan dalam mengidentifikasi jenis-jenis cacat pada kulit secara otomatis. Dengan adanya model deteksi otomatis, maka proses identifikasi cacat kulit yang sebelumnya dilakukan secara manual dapat dilakukan secara lebih cepat dan terukur. Hal ini tentunya juga dapat meningkatkan produktivitas [9][10][11].

Penelitian-penelitian terdahulu telah menunjukkan bahwa deep learning memiliki kinerja yang sangat handal dalam mengklasifikasikan maupun mendeteksi objek. Namun, penggunaan deep learning untuk mengklasifikasikan maupun mendeteksi objek masih memiliki kelemahan, terutama pada eksperimen dengan data sedikit maupun data yang memiliki distribusi tidak seimbang. Kondisi ini dapat menurunkan kinerja deep learning dalam mengenali karakteristik data. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan metode klasifikasi yang berfungsi untuk membedakan jenis-jenis cacat pada kulit menggunakan pendekatan deep learning. Adapun kontribusi yang dilakukan dalam penelitian ini antara lain:

1. Mengaplikasikan data balancing method untuk meningkatkan performa arsitektur deep learning yang dikembangkan.
2. Melakukan studi komparatif terhadap penggunaan data balancing method pada kasus klasifikasi jenis cacat pada kulit yang diusulkan.

## 2. Penelitian yang relevan

Penelitian mengenai data balancing method telah banyak dilakukan oleh beberapa penelitian terdahulu. Penelitian yang dilakukan oleh Ahmad dkk tentang pemanfaatan SMOTE dalam kasus vehicle recognition menggunakan multi layer perceptron. Pada penelitian ini, SMOTE digunakan untuk menyeimbangkan data. Penelitian ini berhasil memperoleh akurasi sebesar 86,02% [12]. Penelitian yang dilakukan oleh Okky dkk, tentang pemanfaatan machine learning untuk memprediksi penyakit liver. Penelitian ini menggunakan metode support vector machine dan logistic regression yang dikombinasikan dengan metode PCA sebagai feature extractor. Dalam penelitian ini juga diterapkan proses akuisisi data yang bertujuan untuk menyeimbangkan jumlah data. Metode yang digunakan dalam proses tersebut adalah metode SMOTE [13]. Penelitian yang dilakukan oleh Chamseddine dkk tentang penerapan SMOTE dan weighted loss untuk mengatasi permasalahan keseimbangan data pada kasus klasifikasi COVID-19 dengan menggunakan dataset x-ray. Adapun metode klasifikasi yang digunakan adalah convolutional neural network yang memanfaatkan teknik transfer learning. Hasil penelitian menunjukkan performa yang sangat baik yakni akurasi sebesar 98,87%, F1\_Score sebesar 98,21%, sensitivity sebesar 98,86%, specificity sebesar 99,43%, precision sebesar 100%, dan AUC sebesar 99,15% [14]. Ozdemir dkk melakukan penelitian tentang penerapan SMOTE untuk mengatasi masalah keseimbangan data pada hyperspectral images. Penelitian ini mengadopsi metode deep learning dikombinasikan dengan SMOTE balanced 5-CV method untuk meningkatkan performa classifier. Hasil penelitian menunjukkan peningkatan performa yang signifikan. Sebelum menerapkan data balancing method, performa yang didapatkan adalah akurasi, presisi, dan recall masing-masing sebesar 93,63%, 92,33%, 88,36% dengan %50-%50 train-test split, dan 94,46%, 94%, 92,24% dengan menggunakan 5-Fold cross-validation yang diaplikasikan pada multi-class classification. Setelah menerapkan SMOTE, hasil performa akurasi, presisi, dan recall masing-masing menjadi 96,41%, 95,6%, 92,53% dengan %50-%50 train-test split dan 96,49%, 95,64%, 93,38% dengan menggunakan 5-Fold cross-validation yang diterapkan pada multi-class classification. Peneliti juga melakukan eksperimen menggunakan beberapa data balancing method lain. Hasil setelah menerapkan Adasyn adalah memperoleh akurasi, presisi, dan recall masing-masing sebesar 95,86%, 93,62%, 87,05% for %50-%50 train-test split and 96,38%, 95,09%, 91,55% for 5-Fold cross-validation using multi-class classification. Hasil setelah menerapkan K-Means balancing adalah mendapatkan akurasi, presisi, dan recall masing-masing sebesar 95,23%, 93,36%, 90,6% for %50-%50 train-test split and 95,74%, 94,72%, 91,94% for 5-Fold cross-validation using multi-class classification. Hasil setelah menerapkan Cluster balancing adalah mendapatkan akurasi, presisi, dan recall masing-masing sebesar 94,83%, 94,1%, 90,07% for %50-%50 train-test split and 96,28%, 95,88%, 92,5% for 5-Fold cross-validation using multi-class classification. Dari beberapa data balancing method tersebut, SMOTE memiliki performa paling baik [15].

Penelitian yang diusulkan oleh Ibrahim dkk tentang penerapan metode synthetic minority oversampling technique and extreme gradient boosting (SMOTE-XGB) untuk mengklasifikasikan lithological images yang dihasilkan dari X-Ray Fluorescence (XRF) juga menunjukkan performa yang sangat baik. Berdasarkan hasil penelitian yang dilakukan, metode yang diusulkan berhasil memperoleh akurasi sebesar 88% dan AUC sebesar 96% yang mana performa tersebut jauh lebih baik dibandingkan dengan performa classifier tanpa menerapkan SMOTE [16]. Penelitian yang diusulkan oleh Widodo dkk tentang penerapan SMOTE untuk menyeimbangkan data pada kasus machine learning-based intrusion detection on multi-class juga menunjukkan performa yang sangat baik. Penelitian ini menggunakan dataset NSL-KDD dan CIC-IDS2017. Adapun metode klasifikasi yang digunakan adalah random forest dan XGBoost. Berdasarkan hasil penelitian, pada dataset NSL-KDD, metode random forest dan SMOTE berhasil mendapatkan akurasi sebesar 99%, presisi sebesar 98%, recall sebesar 97% dan F1-Score sebesar 98%. Sedangkan XGBoost mendapatkan akurasi sebesar 99%, presisi sebesar 98%, recall sebesar 98% dan F1-Score sebesar 98%. Pada dataset CIC-IDS2017, metode random forest dan SMOTE berhasil mendapatkan akurasi sebesar 99%, presisi sebesar 94%, recall sebesar 89% dan F1-Score sebesar 91%. Sedangkan XGBoost mendapatkan akurasi sebesar 99%,

presisi sebesar 95%, recall sebesar 93% dan F1-Score sebesar 94% [17]. Zeng dkk mengusulkan penelitian tentang measuring cyclists' subjective perceptions of the street riding environment dengan menggunakan K-means SMOTE-RF model yang diaplikasi pada street view images. Hasil penelitian memperoleh akurasi tertinggi sebesar 82% dan AUC sebesar 82% [18]. Penelitian yang dilakukan oleh Chen dkk tentang penerapan SMOTE dengan gradient boosting tree pada kasus klasifikasi dengan dataset citra. Penelitian tersebut berhasil memperoleh F1-score sebesar 0.89.

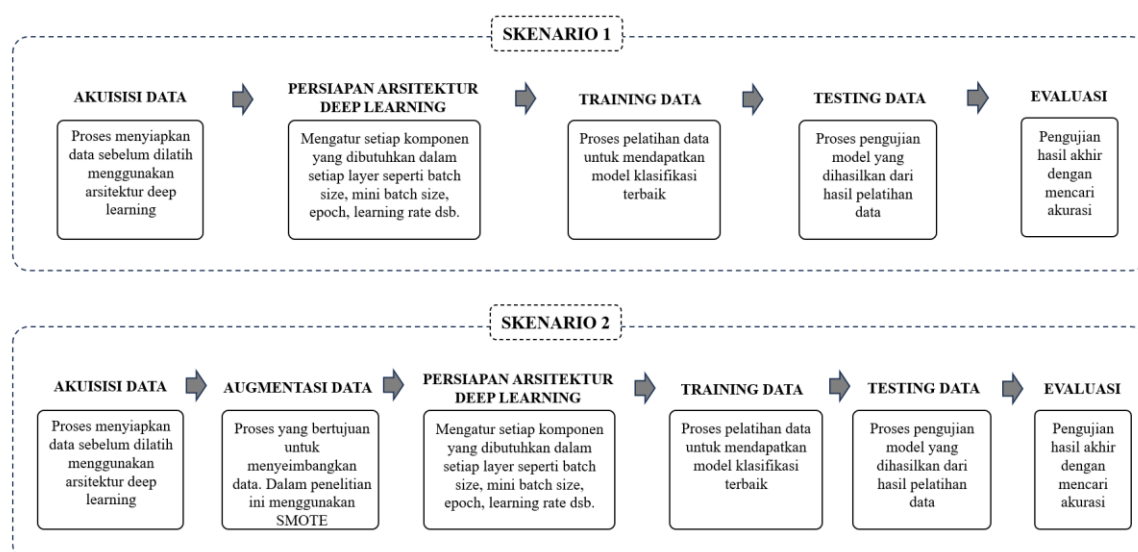
Di era deep learning, dalam konteks klasifikasi citra menggunakan deep learning, masalah ketidakseimbangan kelas dapat terjadi ketika kelas-kelas dalam dataset citra memiliki jumlah sampel yang tidak seimbang. Ini dapat menyebabkan model klasifikasi cenderung memilih kelas mayoritas dan mengabaikan kelas minoritas, yang menghasilkan kinerja yang buruk dalam memprediksi kelas minoritas. SMOTE bekerja dengan menghasilkan sampel sintetis untuk kelas minoritas. Dengan menghasilkan sampel sintetis untuk kelas minoritas, SMOTE dapat membantu model deep learning dalam mempelajari fitur-fitur yang relevan dari kelas-kelas minoritas, sehingga meningkatkan kemampuan model untuk mengklasifikasikan kelas-kelas tersebut dengan lebih baik. Selain itu, dengan meningkatkan jumlah sampel untuk kelas minoritas, SMOTE dapat membantu mengurangi kecenderungan model untuk overfitting pada kelas mayoritas, karena model memiliki lebih banyak data untuk dipelajari. SMOTE juga membantu mengurangi bias dalam model klasifikasi citra dengan memperkenalkan sampel sintetis untuk kelas minoritas, sehingga model memiliki representasi yang lebih seimbang dari semua kelas dalam dataset. Dengan memberikan model deep learning dengan dataset yang lebih seimbang, SMOTE dapat meningkatkan kemampuan model untuk melakukan generalisasi pada data uji yang belum pernah dilihat sebelumnya. Dengan keunggulan-keunggulan tersebut, penelitian ini mengadopsi metode SMOTE untuk menyeimbangkan jumlah data yang digunakan dan untuk meningkatkan kinerja dari arsitektur deep learning.

### 3. Metode

Penelitian ini bertujuan untuk mengembangkan suatu metode berbasis deep learning yang mampu mengidentifikasi jenis-jenis cacat pada kulit. Data yang digunakan pada penelitian ini adalah data publik yang terdiri dari 3600 gambar dan terdistribusi ke dalam dua kelas yakni non-defective leather dan defective leather. Proses ini sangat penting mengingat penentuan artikel produk dilihat dari kualitas kulit. Sehingga, dengan adanya metode deteksi otomatis ini maka proses uji kualitas kulit dapat dilakukan dengan lebih cepat dan lebih objektif. Adapun deskripsi data dan alur penelitian dijelaskan pada sub-bab berikut:

#### 3.1. Kerangka Penelitian

Secara umum, penelitian ini dilakukan dalam dua skenario berbeda. Skenario pertama bertujuan untuk mengetahui kinerja GoogLeNet secara real dengan tanpa melakukan penambahan proses. Sedangkan pada skenario kedua diterapkan data balancing method terlebih dahulu sebelum dilakukan training pada arsitektur GoogLeNet. Hal ini bertujuan untuk menyeimbangkan proporsi data mengingat jumlah atau proporsi data yang tidak seimbang sangat berpengaruh pada hasil. Gambar 1 menunjukkan alur proses dari kedua skenario.



Gambar 1. Alur penelitian

Pada diagram di atas, pada dasarnya proses yang dilakukan di skenario 1 sama dengan skenario 2. Perbedaan terletak pada proses augmentasi data. Proses augmentasi data merupakan proses yang bertujuan untuk membuat data sintesis. Dalam penelitian ini, proses augmentasi data fokus pada proses untuk menyeimbangkan proporsi data.

### 3.2. Data Penelitian

Data yang digunakan dalam penelitian ini merupakan public dataset. Data terdiri dari 3600 citra yang terdistribusi dalam dua kelas. Adapun deskripsi dari data yang digunakan diilustrasikan pada Tabel 1. Sedangkan contoh data yang digunakan diilustrasikan pada Gambar 2.




**Gambar 2.** Contoh citra kulit: (a) defective dan (b) non-defective.

**Tabel 1.** Deskripsi dataset yang digunakan

Komponen	Deskripsi
Jenis citra	Leather defect images
Dimensi	227 x 227 piksel
Ground truth	Klasifikasi yang terdiri dari dua kelas yakni defective dan non-defective.
Jumlah data	Dataset terdiri atas 3600 citra yang terdistribusi dalam proporsi berikut: <ul style="list-style-type: none"> <li>a. non-defective: 600 citra</li> <li>b. defective: 3000 citra</li> </ul>
Sumber data	Dataset yang digunakan merupakan public dataset dari penelitian yang dilakukan oleh Vasagam dkk [4][5]

### 3.3. Metode Penelitian

Penelitian ini terdiri atas tiga tahapan utama, yakni tahap akuisisi data, tahap pelatihan data, dan tahap pengujian data. Pada tahap pertama dilakukan proses akuisisi data yang berfungsi untuk memperbaiki data agar menunjang kinerja dari model deep learning. Dalam penelitian ini tahap akuisisi data difokuskan pada proses penyeimbangan jumlah data. Hal ini didasarkan pada distribusi data yang tidak seimbang sebagaimana diilustrasikan pada Tabel 1 dimana jumlah kelas defective sebanyak 3000 citra sedangkan data non-defective sebanyak 600 citra. Oleh karena itu, pada tahap pertama dilakukan proses balancing data menggunakan metode Synthetic Minority Oversampling Technique atau yang sering dikenal dengan istilah SMOTE [19]. Metode ini bekerja dengan cara melakukan augmentasi data namun juga mempertimbangkan proporsi data berdasarkan kelasnya. Adapun cara kerja dari metode ini dapat dilihat pada Gambar 3 dengan persamaan (1).



Gambar 3. Cara kerja SMOTE.

$$\vec{x} = \vec{a} + w * (\vec{b} - \vec{a}) \tag{1}$$

Secara umum, SMOTE bekerja dengan tiga langkah berikut:

- (1) Memilih nilai  $\vec{a}$  (minority observation) secara random atau acak.
- (2) Tentukan jarak  $\vec{b}$  dengan diawali menentukan nilai k sebagai nilai konstanta dari jumlah persentase proses augmentasi yang diinginkan.
- (3) Membuat sampel-sampel baru  $\vec{x}$  dengan menggunakan persamaan (1) dengan  $w$  adalah bobot yang diambil secara random atau acak.

Setelah proses akuisisi data selesai dilakukan, langkah selanjutnya adalah membuat skenario pelatihan dan pengujian data. Dalam penelitian ini dibuat dua skenario pelatihan dan pengujian data. Skenario pertama adalah melakukan penelitian dan pengujian data dengan menggunakan data original (data sebelum diterapkan SMOTE). Skenario kedua adalah elakukan penelitian dan pengujian data dengan menggunakan data setelah diterapkan SMOTE. Hal ini bertujuan untuk mengevaluasi dan membandingkan bagaimana kinerja model *deep learning* setelah diterapkan *data balancing method*. Adapun deskripsi kedua skenario tersebut diilustrasikan pada Tabel 2.

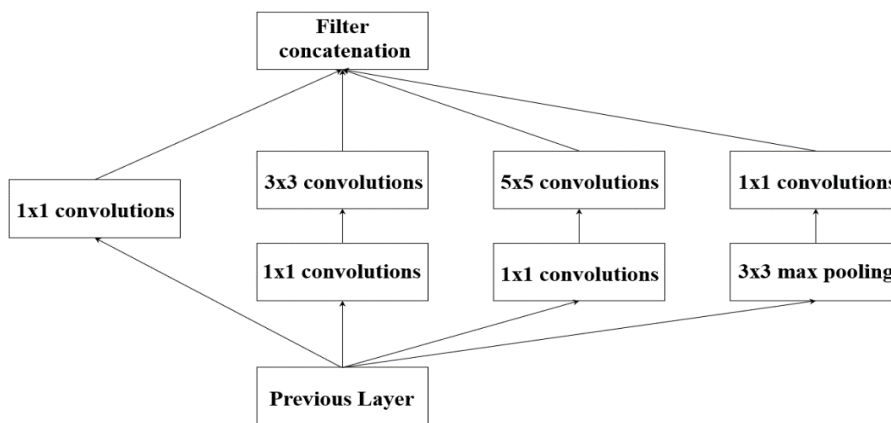
Tabel 2. Deskripsi skenario penelitian

Komponen	Deskripsi Skenario 1	Deskripsi Skenario 2
Proporsi dataset	80:10:10 untuk data training, validation dan testing	80:10:10 untuk data training, validation dan testing
Metode klasifikasi	GoogLeNet	GoogLeNet
Proses tambahan	-	Data balancing process menggunakan SMOTE
Matriks evaluasi	Kuantitatif (akurasi)	Kuantitatif (akurasi)

Setelah persiapan data selesai, tahap selanjutnya adalah melakukan proses pelatihan data dengan menggunakan arsitektur GoogLeNet [19]. Adapun struktur dari arsitektur GoogLeNet diilustrasikan pada Tabel 3 dan Gambar 4.

**Tabel 3.** Struktur arsitektur GoogLeNet [19]

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	



**Gambar 4.** Modul inception [19]

**4. Hasil dan Pembahasan**

Dalam penelitian ini diterapkan dua skenario eksperimen untuk menganalisis efektivitas penggunaan data balancing method dalam rangka meningkatkan kinerja GoogLeNet untuk mengklasifikasikan jenis-jenis cacat pada kulit. Pada skenario pertama, penelitian melakukan pelatihan dan pengujian data dengan menggunakan data original tanpa ada proses tambahan sebelum data dilatih dan diuji. Sedangkan pada skenario kedua, penelitian ini menerapkan data balancing method untuk menyeimbangkan jumlah data sebelum melakukan pelatihan dan pengujian data. Adapun hasil dari penelitian ini dapat dilihat pada Tabel 4. Adapun confusion matrix pada scenario 2 diilustrasikan pada Gambar 5.

**Tabel 4.** Perbandingan hasil dari eksperimen pada skenario 1 dan skenario 2

Komponen	Skenario 1	Skenario 2
Ukuran citra	227 x 227	227 x 227
Proporsi data	80:10:10	80:10:10
Metode klasifikasi	GoogLeNet	GoogLeNet
Batch size	8 (50 epoch)	8 (50 epoch)

Proses tambahan	-	Data balancing process menggunakan SMOTE
Akurasi	81,52%	98,34%

Tabel 4 menunjukkan set-up pada proses training yang dilakukan dalam penelitian ini. Ukuran citra yang digunakan adalah 227 x 227 sesuai dengan kubutahn input data pada arsitektur GoogLeNet. Proporsi data adalah 80:10:10 yang artinya 80% data digunakan sebagai data training, 10% data digunakan sebagai data validation dan 10% data sisanya digunakan sebagai data testing. Kemudian ukuran batch size adalah 8 yang dilatih selama 50 epoch. Berdasarkan hasil eksperimen yang diilustrasikan pada Tabel 4, dapat disimpulkan bahwa penggunaan SMOTE signifikan untuk meningkatkan kinerja arsitektur *deep learning*. Hal ini terlihat dari kenaikan akurasi dari skenario 1 dengan skenario 2. Kenaikan akurasi mencapai lebih dari 15%.

a	b	← Classified as	
240	0	a	: defective
6	115	b	: non-defective

Gambar 5. Confusion matrix

Selain itu, Gambar 5 menunjukkan hanya terdapat 6 data dari 261 data testing yang salah terklasifikasi. Berdasarkan hasil tersebut, maka dapat ditarik kesimpulan bahwa proporsi atau distribusi data sangat berpengaruh pada kinerja metode *deep learning* dalam mengekstrak informasi pada data. Sehingga, pada kasus-kasus data yang tidak seimbang perlu dilakukan proses tambahan seperti menerapkan data balancing method sebelum proses training agar tidak menimbulkan bias pada proses analisis data.

Penelitian sejenis yang bertujuan untuk mengklasifikasikan kulit ke dalam dua kelas (defected leather dan non-defected leather) telah dilakukan oleh peneliti terdahulu. Jawahar dkk menggunakan wavelet feature extraction technique untuk mengklasifikasikan kulit ke dalam dua kelas (defected leather dan non-defected leather). Penelitian ini berhasil memperoleh akurasi 98%. Namun, walaupun memiliki akurasi yang tinggi penelitian tersebut juga memiliki kelemahan. Salah satu kelemahan adalah komputasi yang cukup tinggi karena menggunakan traditional image vision classification method [9].

#### 4. Kesimpulan

Penelitian ini fokus pada analisis efektivitas penggunaan data balancing method untuk meningkatkan kinerja metode deep learning dalam mengklasifikasikan jenis-jenis cacat pada kulit. Penelitian ini memiliki tiga tahapan, yakni tahap akuisisi data, tahap pelatihan data dan tahap pengujian data. Pada tahap akuisisi data, penelitian ini fokus pada proses penerapan data balancing method untuk menyeimbangkan distribusi data. Pada tahap pelatihan dan pengujian data, penelitian ini menggunakan arsitektur GoogLeNet. Dalam penelitian ini dilakukan dua skenario eksperimen. Skenario pertama dilakukan dengan menggunakan data original, sedangkan pada skenario kedua diterapkan data balancing method terlebih dahulu sebelum dilakukan pelatihan data. Hal ini bertujuan untuk melihat bagaimana efektivitas penggunaan data balancing method dalam kasus yang diangkat. Berdasarkan hasil eksperimen yang dilakukan, dapat disimpulkan bahwa penggunaan data balancing method sangat signifikan untuk meningkatkan kinerja arsitektur deep learning. Hal ini terlihat dari kenaikan akurasi dari skenario 1 dengan skenario 2. Kenaikan akurasi mencapai lebih dari 15%. Berdasarkan hasil tersebut, maka dapat ditarik kesimpulan bahwa proporsi atau distribusi data sangat berpengaruh pada kinerja metode deep learning dalam mengekstrak informasi pada data.

#### Daftar Pustaka

- [1] S. Liong, 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. 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: <https://doi.org/10.1080/0951192X.2020.1795928>.
- [3] T. Spahiu, E. Canaj, and E. Shehi, “3D printing for clothing production,” *J. Eng. Fiber. Fabr.*, vol. 15, pp. 1–8, 2020, doi: <https://doi.org/10.1177/1558925020948216>.
- [4] 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.
- [5] 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: <https://doi.org/10.1109/ICCMC53470.2022.9753704>.
- [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: <https://doi.org/10.1109/CVPR.2016.308>.
- [7] L. Alzubaidi *et al.*, “Towards a Better Understanding of Transfer Learning for Medical Imaging: A Case Study,” *Applied Sciences*, vol. 10, no. 13. 2020. doi: <https://doi.org/10.3390/app10134523>.
- [8] L. Alzubaidi *et al.*, “Novel Transfer Learning Approach for Medical Imaging with Limited Labeled Data,” *Cancers (Basel)*, vol. 13, no. 7, p. 1590, Mar. 2021, doi: <https://doi.org/10.3390/cancers13071590>.
- [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: <https://doi.org/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: <https://doi.org/10.1109/NICS.2018.8606836>.
- [11] S.-T. Liong, 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>
- [12] A. Ahmad *et al.*, “Vehicle Recognition using Multi-Layer Perceptron and SMOTE Technique,” in *2022 2nd International Conference of Smart Systems and Emerging Technologies (SMARTTECH)*, 2022, pp. 190–193. doi: <https://doi.org/10.1109/SMARTTECH54121.2022.00049>.
- [13] O. P. Barus, J. Happy, Jusin, J. J. Pangaribuan, S. Z. H, and F. Nadjar, “Liver Disease Prediction Using Support Vector Machine and Logistic Regression Model with Combination of PCA and SMOTE,” in *2022 1st International Conference on Technology Innovation and Its Applications (ICTIIA)*, 2022, pp. 1–6. doi: <https://doi.org/10.1109/ICTIIA54654.2022.9935879>.
- [14] E. Chamseddine, N. Mansouri, M. Soui, and M. Abed, “Handling class imbalance in COVID-19 chest X-ray images classification: Using SMOTE and weighted loss,” *Appl. Soft Comput.*, vol. 129, p. 109588, 2022, doi: <https://doi.org/10.1016/j.asoc.2022.109588>.
- [15] A. Özdemir, K. Polat, and A. Alhudhaif, “Classification of imbalanced hyperspectral images using SMOTE-based deep learning methods,” *Expert Syst. Appl.*, vol. 178, p. 114986, 2021, doi: <https://doi.org/10.1016/j.eswa.2021.114986>.
- [16] B. Ibrahim, I. Ahenkorah, A. Ewusi, and F. Majeed, “A novel XRF-based lithological classification in the Tarkwaian paleo placer formation using SMOTE-XGBoost,” *J. Geochemical Explor.*, vol. 245, p. 107147, 2023, doi: <https://doi.org/10.1016/j.gexplo.2022.107147>.
- [17] A. O. Widodo, B. Setiawan, and R. Indraswari, “Machine Learning-Based Intrusion Detection on Multi-Class Imbalanced Dataset Using SMOTE,” *Procedia Comput. Sci.*, vol. 234, pp. 578–583, 2024, doi: <https://doi.org/10.1016/j.procs.2024.03.042>.
- [18] Q. Zeng, Z. Gong, S. Wu, C. Zhuang, and S. Li, “Measuring cyclists’ subjective perceptions of the street riding environment using K-means SMOTE-RF model and street view imagery,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 128, p. 103739, 2024, doi: <https://doi.org/10.1016/j.jag.2024.103739>.

- 
- [19] C. Szegedy *et al.*, “Going deeper with convolutions,” in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1–9. doi: <https://doi.org/10.1109/CVPR.2015.7298594>.