

KLASIFIKASI MASALAH PADA KULIT WAJAH MENGGUNAKAN METODE CNN

Classification of Facial Skin Problem Using CNN Method

Lalu Habib Satya Wiguna^[1], Fitri Bimantoro^[1,*], Gibran Satya Nugraha^[1]

^[1]Dept Informatics Engineering, Mataram University
Jl. Majapahit 62, Mataram, Lombok NTB, INDONESIA
Email: bimo@unram.ac.id

Facial skin is a part that is very sensitive to germs and bacteria so that anyone can experience facial skin problems regardless of gender, age or background. Facial skin problems that are often experienced, especially in Indonesia, are pockmarks, acne and blackheads. Current developments in artificial intelligence technology can help overcome the need for knowledge about facial skin problems. Convolutional Neural Network (CNN) is an artificial intelligence method used in the field of image classification. Several previous studies used the CNN method and obtained good results for classifying skin diseases. In this research, the CNN method with MobileNet, VGG16, and ResNet50 architecture is used to classify facial skin problems, especially for facial skin problems with pockmarks, acne, and blackheads. This research uses a dataset of pockmarked skin, acne and blackheads collected independently via Google Images. There are 225 total images divided into 75 images for each class of facial skin problems. Of the 225 images, 150 images were used as training data and 75 images as test data. On the training data, augmentation was carried out 15 times so that there were 2250 total images in the training data. Then the data was divided in a ratio of 80% for training data and 20% for validation data, so that the total images for each training and validation data were 1800 and 450 images. The best results were obtained by the VGG16 model with an accuracy of 75% in tests using 224x224 images and RGB color space. At an image size of 128x128 and RGB color space, MobileNet is superior to the other two models with an accuracy of 76%.

Key words: Machine Learning, CNN, Klasifikasi Gambar, Citra Digital, Masalah Kulit Wajah.

I. PENDAHULUAN

Salah satu poin penting yang sering kali mendapat perhatian utama bagi kaum wanita maupun pria adalah wajah. Hal ini dikarenakan wajah berkaitan dengan aspek kecantikan yang dapat dinilai oleh orang lain. Umumnya pada saat bertemu dengan seseorang, hal yang pertama kali dilihat adalah wajah karena merupakan identitas utama seseorang [1]. Kulit wajah merupakan bagian yang sangat sensitif terhadap kuman dan bakteri sehingga masalah pada kulit wajah dapat muncul secara tidak disadari. Masalah kulit wajah yang sering dialami oleh orang-orang pada umumnya terutama di Indonesia yaitu jerawat, bopeng (luka akibat bekas jerawat), komedo, pori-pori besar, kulit kusam, dan kadar minyak berlebih [2]. Dari 2294 responden pada survei yang dilakukan oleh Jakpat [3], tiga teratas untuk kondisi kulit ideal yang diinginkan yaitu kulit

bebas jerawat, kulit mulus (tekstur merata), dan kulit bebas dari komedo. Ketiga kulit ideal tersebut mengacu kepada masalah kulit wajah yaitu jerawat, bopeng, dan komedo. Hasil survei tersebut menggambarkan bahwa persepsi mengenai kondisi kulit ideal dapat berbeda-beda, akan tetapi kulit bebas jerawat, kulit mulus, dan kulit bebas komedo merupakan prioritas utama bagi banyak individu. Hal ini menunjukkan betapa pentingnya perawatan kulit dan upaya untuk mengatasi masalah kulit tertentu dalam mencapai penampilan yang diinginkan. Berdasarkan hal tersebut, penanganan yang tepat dan cepat diperlukan untuk mencegah terjadinya masalah kulit wajah yang berkelanjutan.

Bersamaan dengan pesatnya perkembangan teknologi kecerdasan buatan (*artificial intelligence*) saat ini, sistem cerdas dapat membantu manusia dalam memecahkan banyak permasalahan. Salah satu diantaranya adalah kebutuhan akan pengetahuan untuk masalah pada kulit wajah yang sedang dialami oleh seseorang. Pengembangan sistem cerdas di bidang kecantikan dan kesehatan kulit umumnya menggunakan citra dari masalah kulit wajah. Oleh karena itu, diperlukan pendekatan yang dapat mempelajari pola dan fitur dari suatu citra dan menyesuaikan dengan data yang sudah ada. Salah satu pendekatan yang dapat diimplementasikan untuk masalah yang berkaitan dengan citra adalah dengan menggunakan metode *Convolutional Neural Network* (CNN). CNN merupakan metode klasifikasi yang dapat digunakan untuk mendeteksi atau mengenali sebuah objek pada sebuah citra digital. Kelebihan dari metode CNN adalah memiliki kemampuan untuk memahami struktur dan pola dalam citra yang dapat membantu dalam pengenalan serta klasifikasi citra dengan tingkat akurasi yang tinggi.

Pada penelitian [4], CNN digunakan sebagai model untuk klasifikasi citra dari 3 jenis penyakit kulit. Penelitian tersebut menunjukkan performa yang baik dari CNN dengan akurasi 90% pada saat proses pengujian. Penelitian lainnya [5] menggunakan metode CNN arsitektur MobileNet sebagai pengklasifikasi untuk 7 jenis penyakit kulit mendapatkan hasil yang sangat baik dengan akurasi 94.4%. Penelitian lainnya [6] dengan menggunakan metode CNN juga telah diuji dalam melakukan klasifikasi 5 jenis penyakit kulit dan mendapatkan akurasi 90% dengan menggunakan arsitektur VGG16. Dari beberapa penelitian yang telah disebutkan terkait dengan klasifikasi

masalah atau penyakit kulit di berbagai bagian tubuh termasuk wajah menunjukkan hasil kinerja yang baik dengan menggunakan metode CNN dengan berbagai macam arsitektur. Berdasarkan uraian di atas dan potensi penggunaan teknologi kecerdasan buatan di bidang kecantikan dan kesehatan kulit, penelitian ini bertujuan untuk mengimplementasikan metode CNN dalam melakukan klasifikasi masalah pada kulit wajah, khususnya dalam mengenali dan membedakan jenis masalah seperti bopeng, jerawat, dan komedo. Hasil dari penelitian ini diharapkan mampu untuk memberikan kontribusi di bidang kecantikan dan kesehatan kulit wajah dengan memanfaatkan teknologi kecerdasan buatan dan juga dapat menjadi dasar untuk penelitian selanjutnya.

II. TINJAUAN PUSTAKA

A. Penelitian Terkait

Dalam melakukan penelitian ini, terdapat beberapa penelitian yang telah dilakukan sebelumnya oleh peneliti lainnya dan akan digunakan sebagai referensi untuk penelitian. Penelitian pertama yaitu penelitian dengan judul “Klasifikasi Penyakit Kulit Wajah Menggunakan Metode *Convolutional Neural Network*” yang telah dilakukan oleh Nurkhasanah, Murinto pada tahun 2021. Penelitian terhadap citra penyakit kulit wajah yaitu jerawat, milia, melasma, eksim, dan herpes mendapatkan akurasi sebesar 90% dengan menggunakan arsitektur VGG16 [6]. Pada penelitian ini, percobaan juga dilakukan dengan menggunakan arsitektur CNN yang lain seperti MobileNetV2 dan ResNet50. Dengan menggunakan *dataset* yang sama, pada percobaan menggunakan MobileNetV2 dan ResNet50 keduanya mendapatkan akurasi sebesar 80%. Akurasi yang didapatkan tidak lebih baik jika dibandingkan dengan arsitektur VGG16. Meskipun dari segi akurasi kedua arsitektur tersebut mendapatkan hasil yang terbilang baik, akan tetapi pada saat pengujian masih terdapat banyak citra yang belum dapat dikategorikan sesuai dengan kelasnya karena terjadi *overfitting*.

Penelitian kedua yaitu penelitian dengan judul “Klasifikasi Jenis Jerawat Menggunakan *Convolutional Neural Networks*” yang telah dilakukan oleh Ibrahim, dkk pada tahun 2021 [7]. Pada penelitian ini dilakukan 3 kali percobaan berbeda, yaitu dengan membagi data pelatihan dan data pengujian untuk masing-masing percobaan yaitu 70% dan 30%, 80% dan 20%, serta 90% dan 10%. Dengan menggunakan metode CNN, hasil terbaik yang didapatkan yaitu pada percobaan dengan data pelatihan 90% dan data pengujian 10% yang mendapatkan tingkat akurasi sebesar 91,6% dalam mengenali jenis jerawat. Kemudian terdapat penelitian lainnya dengan judul “A *Web-Based Skin Disease Diagnosis Using Convolutional Neural Networks*” yang telah dilakukan oleh Akyeramfosam dkk pada tahun 2019 dengan metode CNN namun dari segi objeknya berbeda [4]. Penelitian ini menggunakan citra penyakit kulit yaitu *atopic dermatitis*, *acne vulgaris*, *scabies*. Akurasi yang diperoleh dari penelitian ini sebesar 88%.

Selanjutnya terdapat penelitian dengan judul “A *Smartphone-Based Skin Disease Classification Using MobileNet CNN*” yang dilakukan oleh Velasco J. dkk pada tahun 2019 [5]. Pada penelitian ini ada beberapa percobaan yang dilakukan untuk mengatasi masalah tidak seimbangnnya *dataset*. Beberapa cara tersebut yakni *undersampling*, *oversampling*, serta *augmentation*. Penelitian ini juga menggunakan salah satu arsitektur dari CNN yaitu MobileNet. Performa terbaik diperoleh dari percobaan dengan menggunakan gabungan teknik *oversampling* dan *augmentation* dengan akurasi sebesar 94.4%.

Dari beberapa penelitian yang sudah pernah dilakukan sebelumnya untuk klasifikasi masalah pada kulit, keseluruhan penelitian tersebut menggunakan metode CNN dengan arsitektur yang berbeda-beda untuk melakukan klasifikasi pada citra kulit. Hasil yang didapatkan juga cukup baik dari segi akurasi sehingga metode CNN ini baik untuk diterapkan sebagai metode klasifikasi masalah pada kulit. Meskipun menggunakan metode yang sama, namun terdapat perbedaan yakni karakteristik dari objek penelitiannya. Sejauh ini, belum ada penelitian secara spesifik untuk masalah kulit bopeng, jerawat, dan komedo dengan menggunakan metode CNN, oleh karena itu, penulis akan menggunakan metode CNN dalam penelitian ini untuk melakukan klasifikasi masalah pada kulit wajah yaitu bopeng, jerawat, dan komedo.


B. Teori Penunjang

B.1. Masalah Kulit Wajah

Masalah kulit wajah telah menarik banyak perhatian karena memiliki kulit bersih dan tanpa masalah semakin populer dan mempengaruhi masyarakat akhir-akhir ini. Masalah pada kulit wajah dapat mencakup berbagai kondisi atau gangguan yang mempengaruhi penampilan atau kesehatan kulit di area wajah [8]. Beberapa masalah pada kulit wajah yang secara umum dialami oleh wanita maupun pria dari usia remaja hingga dewasa yaitu jerawat, komedo, keriput atau garis halus, eksim, bopeng, hiperpigmentasi, dan lain-lain. Namun, pada penelitian ini akan berfokus pada jerawat, komedo, dan bopeng saja.

B.2. Citra Digital

Citra digital merupakan hasil dari gabungan antara elemen-elemen seperti titik, garis, bidang, dan warna dengan tujuan untuk menghasilkan sebuah tiruan dari objek. Dalam perspektif matematis, citra dapat dianggap sebagai fungsi kontinu dari intensitas cahaya pada bidang dua dimensi, di mana x dan y adalah koordinat spasial (bidang) dan $f(x, y)$ adalah intensitas atau tingkat keabuan citra pada sembarang pasang koordinat (x, y) [9]. Ilustrasi koordinat pada citra digital dapat dilihat pada Gambar 1.



Gambar. 1. Koordinat Citra Digital

Irisan pada baris dan kolom pada posisi (x, y) dalam sebuah citra disebut sebagai piksel. Nilai pada setiap piksel mencerminkan tingkat kecerahan atau warna titik yang sesuai dengan posisinya. Sebuah citra digital juga merepresentasikan sebuah matriks atau array dua dimensi. Terdapat 4 jenis citra yang dibedakan berdasarkan warna dan skala keabuan yaitu citra biner, citra *greyscale*, citra warna berindeks dan citra warna RGB [9].


B.3. Pengolahan Citra Digital

Pengolahan citra digital merupakan suatu proses untuk mengolah piksel-piksel pada citra digital melalui berbagai macam algoritma dengan tujuan untuk memperoleh citra yang sesuai dengan keinginan maupun memperbaiki kualitas dari citra [10]. Contoh sederhana dari pengolahan citra digital dalam kehidupan sehari-hari yaitu ketika sebuah kamera menangkap objek di malam hari yang membuat citra hasil tangkapan pada kamera terlihat gelap maka untuk memperjelas objek tersebut dapat menggunakan aplikasi editing foto sehingga objek dapat terlihat lebih tajam, terang, dan jelas.

Secara umum, ada beberapa operasi dasar pengolahan citra yang sering ditemui atau diaplikasikan dalam kehidupan sehari-hari yaitu *image enhancement*, *image restoration*, *image compression*, *image segmentation*, *image analysis*, dan *image reconstruction* [11].

B.4. Machine Learning

Machine Learning (ML) pada dasarnya adalah proses pelatihan sebuah perangkat lunak yang disebut model, yang berguna untuk mempelajari pola pada sebuah *dataset* [12]. Model ini kemudian dapat digunakan untuk memprediksi data yang belum pernah dikenali sebelumnya. Kemampuan prediksi ini dapat diimplementasikan ke dalam sebuah produk. Contohnya seperti sebuah sistem yang mampu memprediksi video jenis apa saja yang mungkin disukai oleh pengguna, lalu sistem tersebut akan merekomendasikan video-video serupa lainnya pada pengguna [13]. Ilustrasi dari proses *machine learning* dapat dilihat pada Gambar 2.




Gambar. 2. Ilustrasi Proses Machine Learning

ML dibagi menjadi beberapa kategori. Tepatnya ada empat kategori besar, yaitu *supervised learning*, *unsupervised learning*, *semi-supervised learning*, dan *reinforcement learning*. Pembagian kategori tersebut berdasarkan karakteristik data dan jenis supervisi yang didapatkan oleh program selama pelatihan.

B.5. Deep Learning

Deep Learning merupakan cabang dari *machine learning* [14] dengan algoritma jaringan syaraf tiruan yang dapat belajar dan beradaptasi terhadap sejumlah besar data [15]. Algoritma jaringan syaraf tiruan pada *deep learning* terinspirasi dari struktur otak manusia. Algoritma ini memungkinkan mesin untuk melihat pola dari data yang tidak terstruktur atau data yang fiturnya tidak dapat ditentukan secara langsung. Contohnya, data gambar, teks, audio, dan video. *Deep learning* akhir-akhir ini sangat populer karena digunakan sebagai pendekatan untuk melakukan klasifikasi gambar, pengenalan objek, dan pemrosesan bahasa alami [16]. Ilustrasi dari proses *deep learning* dapat dilihat pada Gambar 3.




Gambar. 3. Ilustrasi Proses Deep Learning

Beberapa algoritma yang menerapkan konsep *deep learning* antara lain *Convolutional Neural Network (CNN)* [17], *Deep Belief Network – Deep Neural Network (DBN-DNN)* [18], *Recurrent Neural Network (RNN)* [19].

B.6. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu algoritma dari *deep learning* dan biasanya diimplementasikan untuk melakukan klasifikasi gambar. Algoritma CNN memiliki kemampuan untuk menerima masukan berupa gambar atau citra yang kemudian fiturnya diekstraksi untuk menghasilkan luaran berupa model yang dapat mengenali atau membedakan suatu gambar [20]. Algoritma CNN sendiri menggunakan metode *supervised learning* yang mana *dataset* yang akan dilatih sudah memiliki label sehingga tujuan dari metode ini yaitu untuk mengelompokkan suatu data ke data yang sudah ada. Arsitektur dari CNN tersusun dari beberapa *layer* yang saling berkaitan satu sama lain yang dapat dilihat pada Gambar 4.



Gambar. 4. Pipeline Klasifikasi Gambar pada Arsitektur CNN

Dari Gambar di atas, dapat dilihat bahwa CNN umumnya terdiri dari beberapa jenis *layer*, yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*.

B.7. Metrik Pengujian

Pada model *machine learning*, kinerja model dapat dipantau dengan menggunakan acuan metrik. Dengan adanya metrik pengujian, optimal atau tidaknya kinerja sebuah model dapat diketahui dengan jelas sehingga dapat melakukan revisi untuk model yang sedang dibangun [21]. Dalam bidang klasifikasi gambar, metrik *accuracy* (akurasi), *precision* (presisi), *recall* (daya ingat), dan *F1-Score* merupakan metrik pengujian yang paling umum digunakan untuk menguji apakah model yang dibangun memiliki kinerja yang baik atau tidak. Penjelasan mengenai metrik pengujian tersebut sebagai berikut.

Accuracy merupakan metrik yang paling banyak digunakan dalam mengukur ketepatan sebuah model dalam melakukan prediksi untuk kelas yang sebenarnya. Rumus untuk menghitung *accuracy* pada persamaan (1) berikut.

$$Akurasi = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (1)$$

Keterangan:

TP = *True Positive*

TN = *True Negative*

FP = *False Positive*

FN = *False Negative*

Precision merupakan metrik yang digunakan untuk mengetahui presentase prediksi untuk kelas *True* (*True Positive*) dibandingkan dengan keseluruhan prediksi yang diprediksi sebagai *True* (*True Positive* dan *False Positive*). Rumus untuk menghitung *precision* pada persamaan (2) berikut.

$$Precision = \frac{TP}{(TP+FP)} \quad (2)$$

Recall merupakan metrik yang digunakan untuk mengetahui presentase prediksi untuk kelas *True* dibandingkan dengan keseluruhan prediksi yang sebenarnya adalah kelas *True* (*True Positive* dan *False Negative*). Rumus untuk menghitung *recall* persamaan (3).

$$Recall = \frac{TP}{(TP+FN)} \quad (3)$$

F1-score merupakan kombinasi antara *precision* dan *recall* yang dijadikan sebuah metrik untuk mengukur kinerja dari suatu model dalam melakukan prediksi secara tepat. Untuk menghitung *F1-score* dapat menggunakan rumus pada persamaan (4).

$$f - measure = \frac{2 \times recall \times precision}{recall + precision} \quad (4)$$

III. METODE PENELITIAN

A. Alat dan Bahan

Adapun alat-alat dan bahan yang digunakan dalam penelitian ini adalah sebagai berikut.

A.1. Alat

Berikut merupakan alat-alat berupa *software* yang dimanfaatkan dalam penelitian ini:

1. Visual Studio Code
2. Adobe Photoshop CS6

A.2. Bahan

Bahan yang digunakan pada penelitian ini adalah *dataset* citra kulit yang terdiri dari 3 kelas, yaitu citra kulit dengan masalah bopeng seperti yang terlihat pada gambar 5, jerawat seperti yang terlihat pada gambar 6, dan komedo seperti yang terlihat pada gambar 7 dengan total dari seluruh kelas yaitu 225 buah citra. Pengambilan *dataset* tersebut dilakukan secara manual melalui *Google Images*.



Gambar. 5. Citra Bopeng



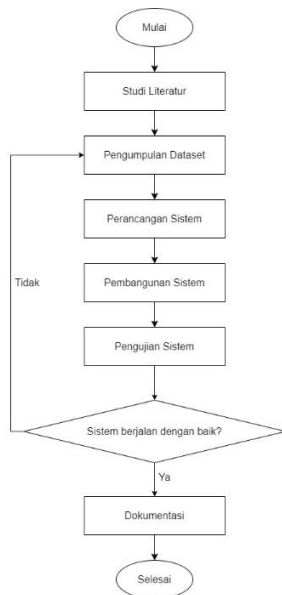
Gambar. 6. Citra Jerawat



Gambar. 7. Citra Komedo

B. Alur Penelitian

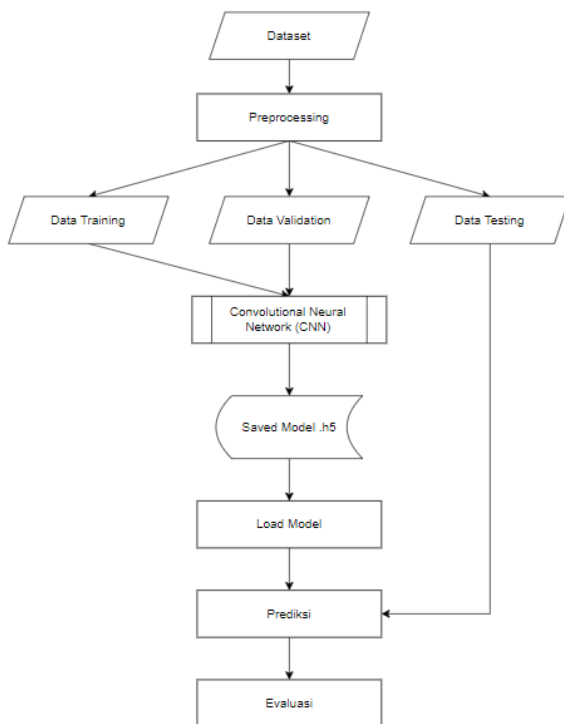
Alur penelitian pada penelitian ini terdiri dari beberapa tahap yaitu, studi literatur, pengumpulan data, perancangan sistem, pembangunan sistem, pengujian sistem, dan dokumentasi.



Gambar. 8. Alur Penelitian

C. Perancangan Sistem

Metode yang digunakan dalam penelitian ini adalah Convolutional Neural Network (CNN) dengan 3 arsitektur yaitu MobileNet, VGG16, dan ResNet50 dengan alur proses pembangunan model dapat dilihat pada Gambar 9.



Gambar. 9. Alur Proses Pembangunan Model

D. Skenario Pengujian

Pada pengujian ini, akan dilakukan beberapa skenario pengujian untuk mendapatkan model terbaik. Adapun

skenario pengujian yang akan dilakukan adalah sebagai berikut.

1. Ukuran Citra

Dalam penelitian ini, ukuran citra yang terdapat pada *dataset* berukuran 224x224 piksel. Kemudian akan dilakukan percobaan dengan mengubah input citra ke dalam ukuran 128x128 piksel untuk selanjutnya dilakukan analisa dengan tujuan untuk menemukan ukuran citra terbaik untuk setiap arsitektur yang digunakan dalam penelitian.

2. Ruang Warna

Pengujian terhadap ruang warna dalam penelitian ini dilakukan dengan melakukan pelatihan pada model menggunakan *dataset* citra grayscale. Tujuan dari penggunaan citra grayscale adalah untuk menguji kinerja dari model yang dibangun dalam mengenali masalah pada kulit wajah di ruang warna yang berbeda.

E. Metrik Evaluasi

Pengujian untuk metrik *accuracy*, *precision*, *recall*, dan *F1-Score* akan dilakukan dalam penelitian ini dengan tujuan untuk mengetahui kinerja dari model yang telah dibangun.

IV. HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Pengumpulan citra masalah pada kulit wajah (bopeng, jerawat, dan komedo) dilakukan secara manual melalui *Google Images*. Jumlah citra yang didapatkan sebanyak 225 citra yang terbagi dalam 3 kelas yaitu sebanyak 75 citra untuk kelas bopeng, 75 citra untuk kelas jerawat, dan 75 citra untuk kelas komedo. Proses pemilihan citra untuk setiap kelas sesuai dengan karakteristik untuk masalah kulit bopeng, jerawat, dan komedo. Dari total 225 citra tersebut, 150 citra akan dimasukkan ke dalam data *training*, dan 75 citra sebagai data *testing*. Untuk data *training* akan dilakukan augmentasi data untuk meningkatkan jumlah dan variasi citra. Sedangkan untuk data testing tidak dilakukan proses augmentasi.

B. Pengolahan Data

Pengolahan data untuk citra masalah pada kulit wajah yang telah dikumpulkan

1. Memangkas Citra (*Crop*)

Pada citra yang telah dikumpulkan sebelumnya masih terdapat elemen yang tidak diinginkan. Maka dari itu, setiap citra yang terdapat pada *dataset* tersebut akan di-*crop* untuk mendapatkan fokus terhadap objek utama. Proses *crop* dilakukan dengan menggunakan ukuran potongan rasio 1:1 atau persegi, sehingga luaran dari proses ini akan menghasilkan citra baru dengan ukuran sisi sama panjang.







Gambar. 10. Pemangkasan Citra

2. Augmentasi

Jumlah citra yang terkumpul terbilang sangat kecil untuk pemrosesan *deep learning* sehingga dilakukan proses augmentasi data dengan tujuan untuk menambah jumlah citra pada *dataset* dengan variasi yang berbeda. Berikut merupakan parameter yang digunakan pada saat proses augmentasi beserta contohnya dapat dilihat pada Tabel I.

TABLE I. AUGMENTASI CITRA


Citra	Keterangan
	Citra asli
	Melakukan rotasi citra
	Menggeser citra secara vertikal
	Menggeser citra secara horizontal

	Mengubah sudut pandang citra
	Memperbesar dan memperkecil citra
	Melakukan pencerminan horizontal terhadap citra
	Melakukan pencerminan vertikal terhadap citra

Hasil dari proses augmentasi data pada citra meningkatkan jumlah citra hingga 15 kali lipat untuk setiap kelas, sehingga total dari keseluruhan citra yang terdapat dalam *dataset* adalah 2250 citra yang terbagi ke dalam masing-masing kelas sebanyak 750 citra.

3. Mengubah Ukuran Citra (*Resize*)


Untuk menyesuaikan ukuran citra dengan input yang dianjurkan pada saat pelatihan model, ukuran citra disesuaikan menjadi 224x224 piksel dan 128x128 piksel. Selain itu, penyesuaian citra ini dilakukan untuk keperluan pengujian kinerja model dengan menggunakan ukuran citra yang berbeda.



Gambar. 11. Pengubahan Ukuran Citra

4. Transformasi Ruang Warna (RGB ke *Greyscale*)


Untuk menguji dan menganalisis performa dari model yang dibangun, dilakukan transformasi terhadap ruang warna dari RGB ke *grayscale* pada *dataset* yang digunakan dalam penelitian ini. *Grayscale* merupakan jenis ruang warna yang hanya memiliki satu saluran warna, di mana nilai intensitas kecerahan citra berkisar dari 0 (hitam) hingga 255 (putih).



Gambar. 12. Transformasi Ruang Warna RGB ke *Grayscale*

5. Pembagian *Dataset*

Secara keseluruhan, alur proses pengolahan data dapat dilihat pada Gambar 13 berikut.



Gambar. 13. Alur Proses Pengolahan Data

Setelah dilakukan proses pengolahan data, didapatkan 4 jenis *dataset* yang akan digunakan pada proses pelatihan yang terbagi menjadi *dataset* citra RGB ukuran 224x224 piksel, *dataset* citra RGB ukuran 128x128 piksel, *dataset* citra *grayscale* ukuran 224x224 piksel, dan *dataset* citra *grayscale* ukuran 128x128 piksel.

Dari 2250 total data, dilakukan pembagian sebanyak 80% sebagai data latih dan 20% sebagai data validasi. Sehingga terdapat 1800 data yang digunakan sebagai data latih dan 450 data sebagai data validasi pada saat proses pelatihan. Selain itu, terdapat 75 data *testing* yang digunakan pada proses pengujian.

C. Pembangunan Model

Dalam penelitian ini, untuk membangun model klasifikasi citra dipilih arsitektur MobileNet, VGG16, dan ResNet50. Pemilihan ketiga arsitektur tersebut berdasarkan performa yang dibuktikan dalam berbagai masalah seperti pengenalan objek maupun klasifikasi citra. Sebelumnya, ketiga arsitektur ini telah menunjukkan performa yang sangat baik seperti pada penelitian [22], [23], dan [24] dalam pengujian menggunakan *dataset* ImageNet yang memiliki total 1000 kelas pada *dataset*-nya. Terdapat juga penelitian yang menunjukkan hasil yang baik pada ketiga model yang diajukan dengan menggunakan *dataset* yang berbeda [6]. Meskipun pada penelitian ini *dataset* yang digunakan relatif rendah, namun hasil dari penelitian ini dapat memberikan pemahaman yang lebih komprehensif terhadap performa dari model untuk membantu dalam memahami kelebihan serta kekurangan dari masing-masing arsitektur tersebut.

Digunakan library TensorFlow untuk inialisasi dan konfigurasi model. Pada model yang akan dibangun, tidak dilakukan penambahan maupun modifikasi pada *layer* ekstraksi fiturnya, sehingga konfigurasi model yang digunakan adalah konfigurasi original dari TensorFlow yang terlihat pada Tabel II.

TABLE II. KONFIGURASI HYPERPARAMETRS

Hyperparameters	Nilai
Optimizer	Adam (default, 0.001)
Epochs	50
Activation Function	Softmax

D. Pengujian Model

Tahap pengujian merupakan tahap di mana model melakukan prediksi pada data uji untuk kemudian diklasifikasikan sesuai dengan kelas-kelas yang telah ditentukan. Sebanyak 75 data *testing* digunakan pada proses pengujian. Data *testing* tersebut merupakan data yang belum pernah dilihat oleh model pada saat proses pelatihan. Hasil pengujian untuk setiap arsitektur akan dicatat dan dianalisa. Model awal yang dibangun menggunakan citra dengan ukuran 224x224 piksel dan ruang warna RGB. Hasil pengujian untuk model CNN dengan arsitektur MobileNet, VGG16, dan ResNet50 pada Tabel III.

TABLE III. PENGUJIAN MODEL UNTUK CITRA 224x224 RGB

Arsitektur	Aktual	Prediksi			Precision	Recall	F1-Score	Accuracy
		B	J	K				
MobileNet	B	16	5	4	0.73	0.64	0.68	69%
	J	2	23	0	0.64	0.92	0.75	
	K	4	8	13	0.76	0.52	0.62	
VGG16	B	14	7	4	0.93	0.56	0.70	75%
	J	0	24	1	0.65	0.96	0.77	
	K	1	6	18	0.78	0.72	0.75	
ResNet50	B	15	2	8	0.54	0.60	0.57	51%
	J	3	12	10	0.67	0.48	0.56	
	K	10	4	11	0.38	0.44	0.41	

Keterangan: B = Bopeng, J = Jerawat, K = Komedo

Pada pengujian tersebut didapatkan hasil terbaik pada model VGG16 untuk citra dengan ukuran 224x224 piksel dan ruang warna RGB dengan akurasi sebesar 75% dibandingkan dengan MobileNet dengan akurasi 69% dan ResNet50 dengan akurasi 51%. Pada Tabel III juga terdapat nilai *precision*, *recall*, dan *f1-score* dari setiap model yang diuji.

Pada model VGG16, performa yang baik ditunjukkan oleh kelas jerawat. Nilai pada recall yang didapatkan untuk kelas jerawat sebesar 96% yang berarti bahwa model dapat memprediksi dengan baik citra jerawat yang memang sebenarnya anggota dari kelas jerawat. Kinerja yang rendah ditunjukkan pada kelas bopeng. Meskipun memiliki nilai *precision* yang tinggi yaitu 93%, hanya sekitar 56% dari total data uji pada kelas bopeng yang berhasil diprediksi dengan benar. Nilai *f1-score* yang dimiliki oleh masing-masing kelas terlihat belum optimal yang berarti bahwa keseimbangan antara *precision* dan *recall* masih belum maksimal. Secara keseluruhan, prediksi yang dilakukan oleh model VGG16 ini lebih condong ke arah jerawat. Hal tersebut dapat disebabkan oleh beberapa faktor, seperti karakteristik fitur dari jerawat yang lebih mendominasi dari bopeng dan komedo, sehingga model cenderung memprediksi bopeng dan komedo sebagai jerawat.

Model dengan arsitektur MobileNet juga menunjukkan performa yang baik pada kelas jerawat. Nilai *recall* yang diperoleh untuk kelas jerawat sebesar 92% yang berarti model ini dapat mengenali anggota dari kelas jerawat dengan baik. Kinerja yang rendah ditunjukkan oleh kelas komedo dengan *recall* sebesar 52% yang berarti bahwa dari total data uji pada kelas komedo hanya 52% saja yang diklasifikasikan dengan benar. Prediksi yang dihasilkan pada model ini juga cenderung ke arah jerawat, sama halnya dengan model VGG16. Meskipun demikian, akurasi yang dihasilkan pada model MobileNet ini lebih rendah dari VGG16. Hal ini menunjukkan bahwa performa dari *depthwise separable convolution* yang dimiliki oleh MobileNet pada penelitian ini belum optimal dibandingkan dengan konvolusi standar yang dilakukan oleh VGG16.

Model dengan arsitektur ResNet50 mendapatkan akurasi paling rendah diantara arsitektur yang lain yaitu sebesar 51%. Perbedaan akurasi ini mengindikasikan bahwa performa dari arsitektur ResNet50 dalam melakukan klasifikasi untuk masalah kulit wajah tidak lebih baik dari kedua model sebelumnya. Nilai *precision* dan *recall* yang rendah ditunjukkan oleh kelas komedo yaitu 38% dan 44% yang berarti bahwa model sulit mengidentifikasi anggota untuk kelas komedo. Selain itu, rata-rata metrik pengujian pada model ini lebih rendah dari dua model yang lain. Hal ini dapat terjadi karena ResNet50 memiliki blok konvolusi dengan susunan *layer* yang kompleks sehingga dapat menghilangkan fitur dari citra dengan variasi rendah pada *dataset*. Seperti yang telah dituliskan sebelumnya bahwa data training yang digunakan pada penelitian ini hanya memiliki 150 citra asli yang diaugmentasikan untuk meningkatkan jumlah data, sehingga penerapan arsitektur ResNet50 untuk *dataset* dengan ukuran kecil yang

memiliki variasi rendah tidak memberikan performa yang maksimal.

1. Perubahan Ukuran Citra

Perubahan ukuran citra dilakukan untuk melihat pengaruh dari ukuran citra terhadap performa model dan akurasi. Hasil dari pengujian ukuran citra 128x128 piksel terhadap model yang dibangun untuk arsitektur MobileNet, VGG16, dan ResNet50 dapat dilihat pada Tabel IV.

TABLE IV. PENGUJIAN MODEL UNTUK CITRA 128x128 RGB

Arsitektur	Aktual	Prediksi			Precision	Recall	F1-Score	Accuracy
		B	J	K				
MobileNet	B	14	6	5	0.82	0.56	0.67	76%
	J	1	23	1	0.72	0.92	0.81	
	K	2	3	20	0.77	0.80	0.78	
VGG16	B	13	4	8	0.93	0.52	0.67	72%
	J	0	21	4	0.72	0.84	0.78	
	K	1	4	20	0.62	0.80	0.70	
ResNet50	B	12	1	12	0.60	0.48	0.53	48%
	J	1	11	13	0.65	0.44	0.52	
	K	7	5	13	0.34	0.52	0.41	

Dari hasil pengujian pada Tabel IV, peningkatan performa terjadi pada model MobileNet terutama untuk kelas jerawat dan komedo. Kinerja yang rendah dari kelas komedo pada model MobileNet dapat diatasi dengan menggunakan citra dengan ukuran piksel yang lebih rendah. Hal tersebut dibuktikan dari peningkatan nilai yang drastis pada *precision*, *recall*, dan *f1-score* untuk kelas komedo. Begitu juga untuk kelas jerawat terjadi peningkatan pada metrik pengujian meskipun tidak terlalu signifikan. Hasil ini menunjukkan bahwa informasi yang diterima oleh MobileNet pada saat proses pelatihan lebih optimal ketika menggunakan citra yang ukurannya lebih kecil. Penurunan performa justru dialami oleh model VGG16 dan ResNet50. Meskipun penurunan yang terjadi tidak signifikan, namun hal tersebut menunjukkan bahwa informasi yang diterima oleh model VGG16 dan ResNet50 menurun ketika menggunakan citra dengan ukuran yang lebih kecil. Secara keseluruhan, performa model MobileNet lebih unggul dari kedua model lainnya dengan akurasi 76%, sedangkan untuk model VGG16 mendapatkan akurasi 72% dan ResNet50 48%.

2. Transformasi Ruang Warna (RGB ke *Greyscale*)

Untuk menguji dan menganalisis performa dari model yang dibangun, dilakukan transformasi terhadap ruang warna dari RGB ke grayscale pada *dataset* yang digunakan dalam penelitian ini. Grayscale merupakan jenis ruang warna yang hanya memiliki satu saluran warna, di mana nilai intensitas kecerahan citra berkisar dari 0 (hitam) hingga 255 (putih). Hasil dari pengujian transformasi warna ke ruang warna grayscale terhadap model yang dibangun untuk arsitektur MobileNet, VGG16, dan ResNet50 dapat dilihat pada Tabel IV.

TABLE V. PENGUJIAN MODEL UNTUK CITRA 224x224 GREYSCALE

Arsitektur	Aktual	Prediksi			Precision	Recall	F1-Score	Accuracy
		B	J	K				
MobileNet	B	14	1	10	0.78	0.56	0.65	68%
	J	3	15	7	0.83	0.60	0.70	
	K	1	2	22	0.56	0.88	0.69	
VGG16	B	4	17	4	1.00	0.16	0.28	64%
	J	0	24	1	0.52	0.96	0.68	
	K	0	5	20	0.80	0.80	0.80	
ResNet50	B	4	19	2	0.50	0.16	0.24	40%
	J	0	25	0	0.39	1.00	0.56	
	K	4	20	1	0.33	0.04	0.07	

Berdasarkan Tabel V, penggunaan ruang warna *grayscale* menunjukkan performa yang tidak lebih baik dari pada RGB. Model MobileNet mendapatkan akurasi yang lebih tinggi dibandingkan kedua model lainnya. Meskipun demikian, metrik pengujian menunjukkan nilai yang belum cukup baik.

Pengujian lainnya terhadap performa model dilakukan dengan menggunakan citra ukuran 128x128 dan ruang warna *grayscale*. Hasil untuk pengujian tersebut dapat dilihat pada Tabel VI.

TABLE VI. PENGUJIAN MODEL UNTUK CITRA 128x128 GREYSCALE

Arsitektur	Aktual	Prediksi			Precision	Recall	F1-Score	Accuracy
		B	J	K				
MobileNet	B	8	9	8	0.89	0.32	0.47	63%
	J	0	16	9	0.62	0.64	0.63	
	K	1	1	23	0.57	0.92	0.71	
VGG16	B	9	6	10	0.90	0.36	0.51	65%
	J	0	21	4	0.66	0.84	0.74	
	K	1	5	19	0.58	0.76	0.66	
ResNet50	B	12	1	12	0.57	0.48	0.52	47%
	J	2	12	11	0.60	0.48	0.53	
	K	7	7	11	0.32	0.44	0.37	

Dari hasil pengujian pada Tabel 4.6, model VGG16 memiliki akurasi paling tinggi yaitu 65% dibandingkan dengan model MobileNet yaitu 63% dan ResNet50 sebesar 47%. Kelas jerawat pada model VGG16 lebih mendominasi dibandingkan dengan kelas bopeng dan komedo.

Pada model MobileNet, didapatkan akurasi yang tidak berbeda jauh dari model VGG16. Nilai recall dari kelas komedo pada model MobileNet merupakan yang paling tinggi dari kelas lainnya dengan angka mencapai 92%. Hal ini menunjukkan pada pengujian dengan ukuran citra 128x128 dan ruang warna *grayscale*, komedo menjadi kelas yang mendominasi untuk model MobileNet.

E. Hasil

Berdasarkan 4 percobaan yang dilakukan pada pengujian model, didapatkan hasil yang tertera pada Tabel VII berikut.

TABLE VII. HASIL PENGUJIAN KESELURUHAN

Arsitektur	Akurasi (%)				Rata-rata
	224x224 RGB	224x224 Grayscale	128x128 RGB	128x128 Grayscale	
MobileNet	69	68	76	63	69
VGG16	75	64	72	65	69
ResNet50	51	40	48	47	46.5

Pada Tabel VII, didapatkan bahwa model dengan arsitektur MobileNet dan VGG16 memiliki rata-rata akurasi yang lebih baik dibandingkan dengan ResNet50. Pada citra dengan ruang warna RGB, model menunjukkan akurasi yang lebih tinggi daripada citra dengan ruang warna *grayscale*. Hal tersebut menunjukkan bahwa citra dengan ruang warna RGB memberikan informasi yang lebih banyak untuk diolah oleh model dibandingkan dengan citra pada ruang warna *grayscale*. Selain itu, pada penelitian ini membuktikan bahwa ruang warna memiliki peran penting dalam membedakan atau menandai suatu objek, sehingga informasi warna dapat membantu model dalam pengambilan keputusan yang tepat.

Secara keseluruhan, dengan menggunakan arsitektur yang sama pada penelitian [6], hasil yang didapatkan pada penelitian kali ini menunjukkan penurunan akurasi. Hal tersebut bisa saja terjadi karena pada penelitian ini konfigurasi model yang digunakan tidak dilakukan modifikasi *layer* maupun hyperparameters. Selain itu, *dataset* yang digunakan juga memiliki pengaruh pada hasil yang diperoleh oleh model, seperti keberagaman data, distribusi kelas yang berbeda, dan kompleksitas permasalahan klasifikasi. Berdasarkan penelitian [25] dan [26] terkait dengan jumlah *dataset* optimal yang digunakan pada pelatihan menggunakan metode CNN, dikatakan bahwa penggunaan *dataset* dengan ukuran yang besar maupun kecil memiliki pengaruh yang berbeda terhadap hasil pengujian namun tidak selalu demikian. Hasil yang diperoleh dipengaruhi oleh sejauh mana data yang terdapat pada *dataset* mampu merepresentasikan karakteristik dari setiap kelas secara efektif. Oleh karena itu, penggunaan *dataset* yang relatif kecil mempunyai kemungkinan memberikan hasil yang lebih tinggi dibandingkan *dataset* yang besar tergantung dari representasi fitur dan karakteristik dari citra yang dimiliki oleh *dataset* tersebut, begitu juga sebaliknya.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan penelitian yang telah dilakukan, terdapat beberapa kesimpulan, antara lain:

1. Dalam melakukan klasifikasi, model dengan arsitektur MobileNet dan VGG16 sudah menunjukkan hasil yang baik, namun untuk model dengan arsitektur ResNet50, belum menunjukkan performa yang optimal dalam melakukan klasifikasi citra masalah pada kulit wajah untuk penelitian ini. Hal tersebut dapat terjadi karena *dataset* yang digunakan pada saat pelatihan relatif kecil untuk ResNet50 yang biasanya digunakan untuk tugas yang kuat dan kompleks dengan *dataset* yang besar sehingga dapat disimpulkan bahwa arsitektur ResNet tidak cocok untuk tugas yang sederhana.
2. Pada citra dengan ukuran 224x224 dan ruang warna RGB, model VGG16 lebih unggul dibandingkan MobileNet dan ResNet50 dengan akurasi yang diperoleh yaitu 75% pada VGG16, diikuti dengan MobileNet sebesar 69% dan ResNet50 sebesar 51%. Kemudian ketika ukuran citra diturunkan ke 128x128 piksel dan ruang warna RGB, akurasi paling tinggi didapatkan oleh model MobileNet dengan nilai akurasi

sebesar 76%, diikuti oleh VGG16 sebesar 72% dan ResNet50 sebesar 48%.

3. Ruang warna memiliki pengaruh yang signifikan terhadap performa model, di mana pada hasil pengujian menunjukkan bahwa akurasi yang diperoleh mengalami penurunan ketika dilakukan transformasi warna dari RGB ke grayscale.
4. Perubahan ukuran citra memiliki pengaruh yang berbeda untuk performa setiap arsitektur. Penurunan akurasi terjadi pada model VGG16 dan ResNet50 ketika resolusi citra diturunkan. Sebaliknya model MobileNet mengalami peningkatan akurasi pada saat resolusi citra diturunkan.

B. Saran

Untuk pengembangan pada penelitian selanjutnya, terdapat saran berdasarkan penelitian ini sebagai berikut:

1. Pengumpulan *dataset* didapatkan dari klinik kecantikan maupun dokter kulit untuk mendapatkan kualitas gambar yang lebih maksimal.
2. Selain bopeng, jerawat, dan komedo, untuk penelitian selanjutnya diharapkan dapat menambah kelas untuk masalah kulit wajah yang lain.
3. Untuk interpretasi hasil dan evaluasi performa model secara menyeluruh, dapat ditambahkan jenis kulit normal sebagai *baseline* model pada pengembangan selanjutnya.
4. Untuk meningkatkan performa model dalam melakukan klasifikasi, dapat dilakukan percobaan dengan melakukan modifikasi *layer* serta *hyperparameter tuning*.
5. Untuk pengembangan selanjutnya diharapkan model yang dibangun sudah dapat diterapkan ke dalam sebuah aplikasi sehingga dapat digunakan oleh banyak orang. Contohnya seperti aplikasi rekomendasi *skincare*.

REFERENCES

- [1] A. Aseprianto, "Sistem Pakar Masalah Kulit Untuk Penentuan Ketepatan Perawatan Wajah Berminyak Dengan Metode Forward Chaining," *JURNAL PERENCANAAN, SAINS DAN TEKNOLOGI (JUPERSATEK)*, vol. 4, no. 1, pp. 758–765, Jul. 2021, [Online]. Available: <https://ejournal.uniks.ac.id/index.php/JUPERSATEK/article/view/1594>
- [2] ZAP Clinic, "ZAP Beauty Index 2018/2019," 2020. Accessed: Aug. 04, 2023. [Online]. Available: <https://zapclinic.com/zapbeautyindex/2020>
- [3] JAKPAT, "2021 Beauty Trends - Jakpat Survey Report," 2021. Accessed: Aug. 04, 2023. [Online]. Available: <https://blog.jakpat.net/2021-beauty-trends-jakpat-survey-report/>
- [4] S. Akyeramfo-Sam, A. Addo Philip, D. Yeboah, N. C. Nartey, and I. Kofi Nti, "A Web-Based Skin Disease Diagnosis Using Convolutional Neural Networks," *International Journal of Information Technology and Computer Science*, vol. 11, no. 11, pp. 54–60, Nov. 2019, doi: 10.5815/ijitcs.2019.11.06.
- [5] J. Velasco, "A Smartphone-Based Skin Disease Classification Using MobileNet CNN," *International Journal of Advanced Trends in Computer Science and Engineering*, pp. 2632–2637, Oct. 2019, doi: 10.30534/ijatcse/2019/116852019.
- [6] Nurkhasanah and Murinto, "Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network," *Sainteks*, vol. 18, no. 2, p. 183, Feb. 2022, doi: 10.30595/sainteks.v18i2.13188.
- [7] I. Hasan, S. Suprayogi, and H. B. Dyah, "Klasifikasi Jenis Jerawat Menggunakan Convolutional Neural Networks," *eProceedings of Engineering*, vol. 8, no. 1, 2021, Accessed: Jun. 08, 2023. [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/download/14284/14068>
- [8] S. Bekmirzaev, S. Oh, and S. Yo, "RethNet: Object-by-Object Learning for Detecting Facial Skin Problems," in *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, IEEE, Oct. 2019, pp. 425–433. doi: 10.1109/ICCVW.2019.00054.
- [9] D.-H. Xia *et al.*, "Review-Material Degradation Assessed by Digital Image Processing: Fundamentals, Progresses, and Challenges," *J Mater Sci Technol*, vol. 53, pp. 146–162, Sep. 2020, doi: 10.1016/j.jmst.2020.04.033.
- [10] P. Mahakavi and R. Chithra, "Impact Resistance, Microstructures and Digital Image Processing on Self-Compacting Concrete with Hooked End and Crimped Steel Fiber," *Constr Build Mater*, vol. 220, pp. 651–666, Sep. 2019, doi: 10.1016/j.conbuildmat.2019.06.001.
- [11] R. Ravikumar and V. Arulmozhi, "Digital Image Processing-A Quick Review," *International Journal of Intelligent Computing and Technology (IJICT)*, vol. 2, no. 2, pp. 11–19, 2019, Accessed: Jun. 06, 2023. [Online]. Available: <https://www.diva-portal.org/smash/get/diva2:1207144/FULLTEXT01.pdf>
- [12] G. Carleo *et al.*, "Machine Learning and The Physical Sciences," *Rev Mod Phys*, vol. 91, no. 4, p. 045002, Dec. 2019, doi: 10.1103/RevModPhys.91.045002.
- [13] S. Roy and S. C. Guntuku, "Latent Factor Representations for Cold-Start Video Recommendation," in *Proceedings of the 10th ACM Conference on Recommender Systems*, New York, NY, USA: ACM, Sep. 2016, pp. 99–106. doi: 10.1145/2959100.2959172.
- [14] C. Janiesch, P. Zschech, and K. Heinrich, "Machine Learning and Deep Learning," *Electronic Markets*, vol. 31, no. 3, pp. 685–695, Sep. 2021, doi: 10.1007/s12525-021-00475-2.

- [15] J. Ott, A. Atchison, P. Harnack, A. Bergh, and E. Linstead, "A Deep Learning Approach to Identifying Source Code in Images and Video," in *Proceedings of the 15th International Conference on Mining Software Repositories*, New York, NY, USA: ACM, May 2018, pp. 376–386. doi: 10.1145/3196398.3196402.
- [16] S. Li, W. Song, L. Fang, Y. Chen, P. Ghamisi, and J. A. Benediktsson, "Deep Learning for Hyperspectral Image Classification: An Overview," Oct. 2019, doi: 10.1109/TGRS.2019.2907932.
- [17] B. Bayar and M. C. Stamm, "A Deep Learning Approach to Universal Image Manipulation Detection Using a New Convolutional Layer," in *Proceedings of the 4th ACM Workshop on Information Hiding and Multimedia Security*, New York, NY, USA: ACM, Jun. 2016, pp. 5–10. doi: 10.1145/2909827.2930786.
- [18] M. Tanaka and M. Okutomi, "A Novel Inference of a Restricted Boltzmann Machine," in *2014 22nd International Conference on Pattern Recognition*, IEEE, Aug. 2014, pp. 1526–1531. doi: 10.1109/ICPR.2014.271.
- [19] R. Zhao, J. Xue, J. Li, W. Wei, L. He, and Y. Gong, "On Addressing Practical Challenges for RNN-Transducer," *2015 IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU)*, Apr. 2021.
- [20] I. Mudzakir and T. Arifin, "Klasifikasi Penggunaan Masker dengan Convolutional Neural Network Menggunakan Arsitektur MobileNetv2," *EXPERT: Jurnal Manajemen Sistem Informasi dan Teknologi*, vol. 12, no. 1, p. 76, Jun. 2022, doi: 10.36448/expert.v12i1.2466.
- [21] H. M and S. M.N, "A Review on Evaluation Metrics for Data Classification Evaluations," *International Journal of Data Mining & Knowledge Management Process*, vol. 5, no. 2, pp. 01–11, Mar. 2015, doi: 10.5121/ijdkp.2015.5201.
- [22] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," *Microsoft Research*, Dec. 2015.
- [23] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," *Google Inc.*, Apr. 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>
- [24] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *Visual Geometry Group, Department of Engineering Science, University of Oxford*, Sep. 2014, [Online]. Available: <http://arxiv.org/abs/1409.1556>
- [25] C. Luo, X. Li, J. Yin, J. He, D. gao, and J. Zhou, "How Does the Data Set and the Number of Categories Affect CNN-based Image Classification Performance?," *Journal of Software*, pp. 168–181, Apr. 2019, doi: 10.17706/jsw.14.4.168-181.
- [26] A. Althnian *et al.*, "Impact of Dataset Size on Classification Performance: An Empirical Evaluation in the Medical Domain," *Applied Sciences*, vol. 11, no. 2, p. 796, Jan. 2021, doi: 10.3390/app11020796.