

Optimalisasi Model *Deep Learning* CNN Berbasis Android untuk Identifikasi Jenis Jerawat dan Rekomendasi Perawatan Kulit Wajah

Prayitno¹, Moh. Abduh²

¹ Jurusan Teknik Elektro, Politeknik Negeri Semarang, Jl. Prof. Soedarto, Kota Semarang

² Universitas Muhammadiyah Malang, Jl. Raya Tlogomas 246 Malang

Kontak Person:

Prayitno

Jl. Prof. Soedarto, Tembalang, Kec. Tembalang, Kota Semarang, Jawa Tengah 50275

E-mail: prayitno@polines.ac.id

Abstract

Wajah memiliki peran krusial dalam membentuk penampilan seseorang. Namun, beragam permasalahan kulit, termasuk jerawat, dapat menurunkan rasa percaya diri. Meskipun tidak mengancam nyawa, jerawat yang parah berpotensi memengaruhi kondisi psikologis serta kesehatan mental individu. Artikel ini berfokus pada pengembangan aplikasi cerdas berbasis Android yang mampu mendeteksi jenis jerawat melalui analisis citra, sekaligus memberikan rekomendasi perawatan kulit wajah yang sesuai. Metode *Deep Learning Convolutional Neural Network (CNN)* diterapkan untuk mengklasifikasikan citra dengan membandingkan kinerja beberapa model, yaitu *MobileNetV2*, *NASNetMobile*, *ResNet50V2*, *DenseNet121*, dan *EfficientNetB0*. Hasil pengujian menunjukkan bahwa model *ResNet50V2* memiliki tingkat akurasi tertinggi dalam mengidentifikasi jenis jerawat, yakni sebesar 92,59%. Aplikasi ini mengelompokkan jerawat ke dalam kategori komedo (*blackheads*), papula, pustula, nodul, dan kondisi wajah normal. Selain klasifikasi citra wajah, aplikasi juga merekomendasikan metode perawatan yang paling tepat berdasarkan hasil pengenalan tersebut. Dengan demikian, sistem cerdas ini diharapkan dapat membantu pengguna mengenali jenis jerawat yang dialami, menentukan perawatan yang efektif, mempercepat proses penyembuhan, serta meningkatkan kepercayaan diri.

Kata Kunci: *Deep Learning*, Klasifikasi Jerawat, Aplikasi Android, *Convolutional Neural Network (CNN)*, Deteksi Citra.

1. PENDAHULUAN

Penampilan merupakan hal pertama yang umumnya diperhatikan oleh orang lain, dan wajah menjadi salah satu aspek utama yang menarik perhatian, termasuk kondisi kulit. Memiliki kulit wajah yang sehat dan bersih adalah dambaan setiap individu. Namun, jika kesehatan serta kebersihan kulit wajah tidak terjaga dengan baik, risiko munculnya berbagai masalah kulit, termasuk jerawat, akan meningkat. Berdasarkan *Global Burden of Disease (2019)*, dari 4,94 juta responden di 204 negara, tercatat 3,52 juta di antaranya mengalami *Acne Vulgaris* atau jerawat [1]. Jerawat umumnya muncul pada masa pubertas, yakni dalam rentang usia 15–49 tahun, dengan tingkat keparahan yang bervariasi. Meskipun tidak mengancam jiwa, jerawat parah dapat memengaruhi kondisi psikologis serta mental individu [2]. Jerawat merupakan peradangan pada kulit wajah, yang umumnya dialami oleh remaja, dan bersifat polimorf dengan berbagai bentuk seperti papula, pustula, nodul, serta komedo [3]. Setiap jenis jerawat memiliki karakteristik dan metode penanganan yang berbeda.

Namun, banyak individu masih kesulitan mengenali jenis jerawat yang dialami serta menentukan perawatan yang tepat. Seiring kemajuan era digital, teknologi dapat dimanfaatkan untuk memperoleh informasi terkait perawatan kulit berjerawat. Salah satu pendekatan yang menjanjikan adalah pemanfaatan sistem cerdas berbasis *Deep Learning*, yang mampu mempelajari data pelatihan untuk mendeteksi jenis jerawat sekaligus merekomendasikan perawatan yang sesuai. Penelitian sebelumnya, seperti studi “*Automatic Acne Detection for Medical Treatment*” [4], telah berupaya mendeteksi jerawat melalui pengolahan citra dan metode *binary thresholding*. Pada penelitian tersebut, citra RGB dikonversi ke grayscale untuk normalisasi, serta HSV untuk menentukan nilai luminans, menghasilkan tingkat akurasi sekitar 70%. Nilai akurasi ini masih relatif rendah, sehingga sistem belum mampu memprediksi jenis jerawat dengan optimal.

Menyikapi keterbatasan ini, aplikasi cerdas dengan nama *Mooi Skin* diusulkan, yaitu aplikasi untuk deteksi jerawat berbasis citra yang memanfaatkan metode *Convolutional Neural Network (CNN)* dan membandingkan kinerja beberapa model *CNN deep learning*, antara lain *MobileNetV2*, *NASNetMobile*, *ResNet50V2*, *DenseNet121*, serta *EfficientNetB0*, guna memperoleh model dengan

kinerja terbaik. Mengingat Android merupakan salah satu sistem operasi ponsel cerdas terpopuler, platform ini digunakan untuk mengimplementasikan sistem cerdas tersebut. Diharapkan, sistem *deep learning* berbasis Android ini dapat membantu pengguna mengidentifikasi jenis jerawat dan memberikan rekomendasi perawatan kulit yang tepat, sehingga waktu, biaya, dan efektivitas perawatan kulit berjerawat dapat dioptimalkan.

2. STUDI LITERATUR

Pengembangan aplikasi memanfaatkan dataset citra jerawat dari *acne grading dataset* yang tersedia di kaggle.com [5]. Dataset tersebut dikelompokkan berdasarkan dua kriteria, yaitu tingkat keparahan dan jenis jerawat. Tingkat keparahan dibagi menjadi tiga kategori, yaitu ringan (*level 0*), sedang (*level 1*), dan berat (*level 3*). Sementara itu, pengelompokan berdasarkan jenis jerawat terdiri dari empat kategori, yakni papula, pustula, nodul, serta *cristae*. Dataset yang digunakan berupa citra berukuran 500 x 555 piksel. Selanjutnya, data tersebut dilatih menggunakan algoritma CNN. Dataset ini disiapkan untuk mendeteksi tingkat keparahan jerawat dan jenisnya. Proses deteksi objek dilaksanakan dengan memanfaatkan model EfficientDet-Lite yang akan diimplementasikan dalam aplikasi ini. Pengguna dapat memanfaatkan aplikasi secara real-time, yakni dengan mengambil foto baru atau mengunggah citra yang sudah tersedia di perangkat, sehingga aplikasi dapat memproses data tersebut untuk mendeteksi permasalahan jerawat.

Pancholi dkk menggunakan 200 citra yang terbagi dalam dua kategori, yakni 100 citra kulit normal dan 100 citra kulit berjerawat [6]. Dataset ini dilatih menggunakan berbagai model, antara lain Inceptionv3, VGG16, dan VGG19, guna memperoleh hasil terbaik. Selanjutnya, hasil tersebut dianalisis menggunakan beberapa algoritma seperti AdaBoost, KNN, Neural Network, Random Forest, dan SVM untuk mengklasifikasikan citra menjadi berjerawat atau normal.

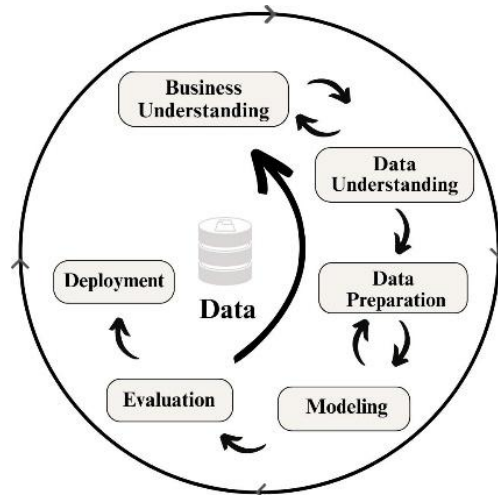
Dalam penelitian Prodeep et al., penulis memanfaatkan dataset dari Kaggle.com yang terdiri atas sekitar 1604 citra wajah dengan kondisi jerawat dan rosacea serta 270 citra tubuh dengan kondisi serupa [7]. Dataset ini mencakup 1257 citra wajah dengan berbagai jenis jerawat dan 347 citra rosacea, serta 249 citra bagian tubuh yang mengalami berbagai jenis jerawat dan 21 citra rosacea. Seluruh data dibagi dengan proporsi 80:20 untuk data latih dan uji. Sistem yang dibangun mampu membedakan kondisi jerawat dari rosacea melalui analisis citra.

Chin et al. menjelaskan bahwa sistem yang dikembangkan mampu mendeteksi berbagai masalah kulit seperti kerutan, pori-pori, dan jerawat melalui ponsel cerdas dengan metode keputusan multifitur [8]. Setelah pengguna memasukkan citra wajah, sistem melakukan pra-pemrosesan citra, kemudian membagi wajah menjadi 11 area untuk tahap pengenalan berikutnya. Metode multifitur digunakan untuk mendeteksi berbagai kondisi kulit. Setelah pengguna menerima hasil pendeteksian kondisi kulitnya, sistem juga memberikan rekomendasi perawatan kulit yang sesuai.

Chantharaphaichi et al. mengembangkan sistem yang secara otomatis mendeteksi dan memisahkan jerawat dari permasalahan wajah lainnya melalui algoritma khusus [4]. Algoritma yang diusulkan mencakup konversi citra RGB ke grayscale untuk memudahkan pemrosesan, normalisasi grayscale, konversi citra ke ruang warna HSV untuk memanfaatkan nilai luminans (V), ekstraksi ROI, penggunaan ambang batas biner, eliminasi fitur non-ROI, serta pemberian penanda pada hasil deteksi yang kemudian di-overlay pada citra asli. Nilai sensitivitas dan presisi yang diperoleh relatif tinggi, yaitu masing-masing 86,37% dan 80%. Namun, akurasi keseluruhan masih tergolong rendah, hanya sekitar 70%.

3. METODOLOGI PENELITIAN

Penelitian ini menghasilkan sebuah aplikasi berbasis Android yang memanfaatkan citra masukan dari galeri atau tangkapan foto secara langsung, untuk kemudian memberikan luaran berupa jenis jerawat dan rekomendasi perawatan yang sesuai. Pendekatan yang digunakan ialah algoritma *Convolutional Neural Network* (CNN). Dalam penerapannya, penelitian ini mengadopsi metodologi *Cross-Industry Standard Process for Data Mining* (CRISP-DM) untuk tahapan pengolahan data. Beberapa tahapan CRISP-DM yang dilakukan meliputi pemahaman bisnis (*Business Understanding*), pemahaman data (*Data Understanding*), persiapan data (*Data Preparation*), pemodelan (*Modeling*), evaluasi (*Evaluation*), serta penerapan (*Deployment*), seperti yang ditunjukkan pada Gambar 1.



Gambar 1 Cross-Industry Standard Process for Data Mining (CRISP-DM).

a. Business Understanding

Tahap pertama dalam model CRISP-DM adalah memahami tujuan yang ingin dicapai serta permasalahan yang hendak diselesaikan. Pada tahap ini, fokus diarahkan untuk menelaah permasalahan yang ada, menetapkan persyaratan fungsional maupun non-fungsional, serta mengidentifikasi sasaran yang hendak diwujudkan. Dalam konteks ini, masih banyak penderita jerawat yang kesulitan membedakan jenis jerawat yang mereka alami serta menentukan perawatan yang tepat. Oleh karena itu, penerapan sistem deteksi cerdas berbasis Android dengan memanfaatkan CNN diharapkan dapat menjadi solusi untuk membantu pengguna mengenali jenis jerawat yang mereka hadapi, sekaligus mempermudah dalam memilih cara penanganannya.

b. Data Understanding

Pada tahap ini, peneliti perlu mengumpulkan data yang relevan dengan tujuan penelitian. Selain pengumpulan data, diperlukan pula deskripsi serta evaluasi kualitas data tersebut. Data yang dikumpulkan akan digunakan dalam proses pelatihan model aplikasi yang tengah dikembangkan. Dalam penelitian ini, data diambil dari Kaggle.com dan Dermnetnz.org, yaitu platform yang menyediakan kumpulan data serta informasi terkait bidang penelitian ini. Dataset yang diperoleh dipersiapkan untuk mendeteksi dan mengklasifikasikan jenis jerawat dengan memanfaatkan Algoritma CNN.

c. Data Preparation

Tahap ini melibatkan pengolahan dataset mentah menjadi dataset akhir yang siap digunakan. Dataset dibagi dengan rasio 85% untuk pelatihan (training) dan 15% untuk pengujian (testing). Data pelatihan digunakan dalam proses pembelajaran model, sedangkan data pengujian digunakan sebagai validasi untuk mencegah terjadinya kesalahan pada pemodelan. Total dataset yang digunakan berjumlah 360 data, terdiri atas 306 data pelatihan dan 54 data pengujian. Jumlah citra yang digunakan pada setiap kelas ditampilkan pada Tabel I. Selanjutnya, dilakukan pelabelan data ke dalam 5 kategori, yaitu komedo (blackheads), papula, pustula, nodul, dan wajah normal. Contoh dataset yang digunakan dapat dilihat pada Gambar 2.

Tabel 1. Pembagian data untuk *Training* dan *Testing*

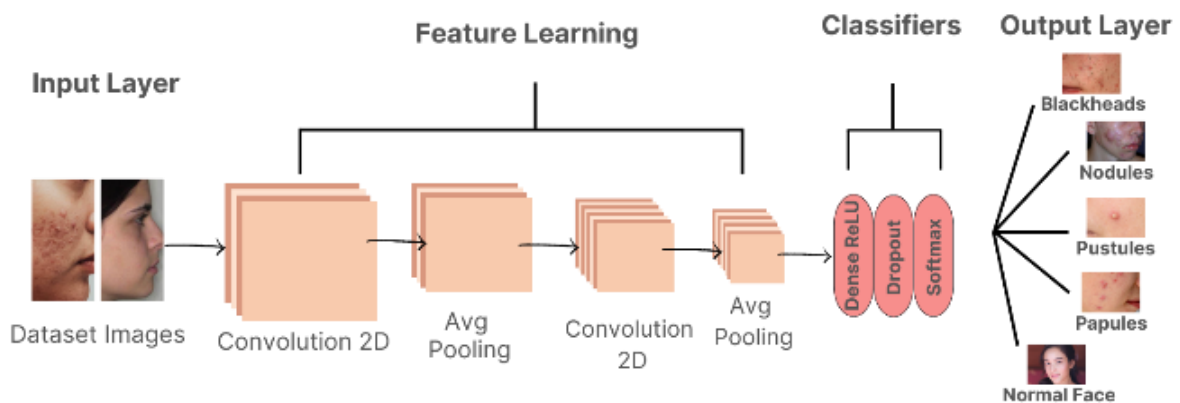
	Total	Training	Testing
Blackheads	68	59	9
Papules	73	61	12
Pustules	69	59	10
Nodules	78	66	12
Normal Face	72	61	11
Total	360	306	54



Gambar 2 Beberapa Contoh Gambar Jerawat dari *Acne dataset*.

d. *Modelling*

Pada tahap ini, proses pemodelan dilakukan dengan memanfaatkan dataset yang telah disiapkan pada tahap sebelumnya. Seluruh dataset akan diproses dalam tahapan pelatihan guna menghasilkan model terbaik yang dapat diimplementasikan pada aplikasi berbasis perangkat seluler. CNN merupakan arsitektur jaringan saraf tiruan yang umumnya digunakan untuk pengolahan dan analisis data citra maupun visual. Melalui penggunaan lapisan konvolusi, pooling, serta fully connected, CNN mampu mengekstraksi fitur-fitur penting dan memberikan prediksi yang akurat dalam tugas pengenalan pola visual. Dalam penelitian ini, model yang diterapkan meliputi MobileNetV2, NASNetMobile, ResNet50V2, DenseNet121, serta EfficientNetB0. Gambar 3 memperlihatkan arsitektur lengkap sistem klasifikasi jenis jerawat dan wajah normal menggunakan model CNN tersebut.



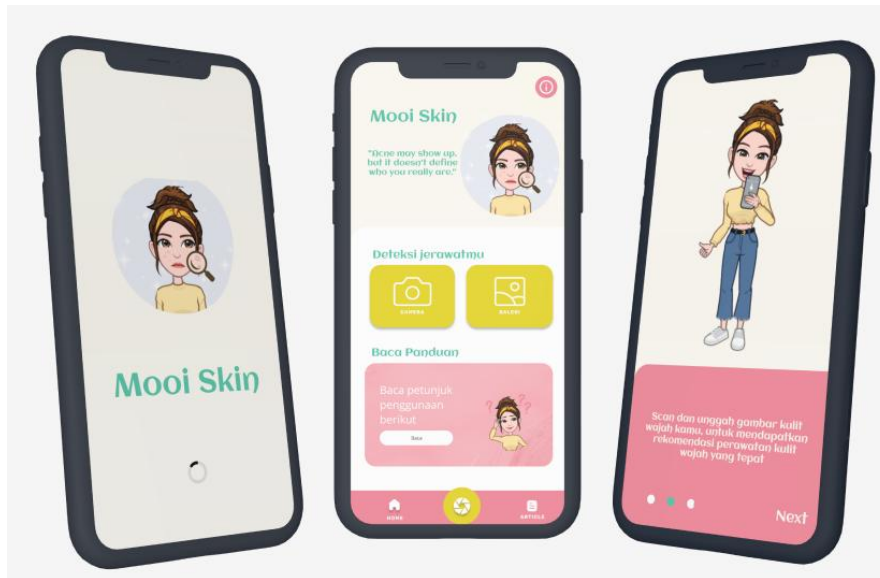
Gambar 3 Arsitektur model Deep Learning CNN

e. *Evaluation*

Pada tahap ini, kinerja algoritma dievaluasi dengan menilai tingkat performa model yang dihasilkan. Untuk melakukan evaluasi, digunakan matriks kebingungan (Confusion Matrix) dengan memperhatikan nilai akurasi, presisi, dan recall. Confusion Matrix dimanfaatkan sebagai alat analisis untuk menilai sejauh mana hasil prediksi model sesuai dengan kondisi sebenarnya.

f. *Deployment*

Tahap akhir mencakup persiapan dan implementasi model ke perangkat seluler. Pada tahap ini, aplikasi dikembangkan pada sistem operasi Android menggunakan Android Studio serta bahasa pemrograman Dart. Penerapan ini memanfaatkan berbagai pustaka yang disediakan oleh TensorFlow dan memanfaatkan kode sumber dari tflite model maker. Model yang telah diciptakan atau diekspor dalam format berkas dengan ekstensi .tflite kemudian diintegrasikan ke dalam perangkat seluler. Hasil penerapan aplikasi ini dapat dilihat pada Gambar 4.



Gambar 4 Aplikasi Android

4. HASIL DAN PEMBAHASAN

Bab ini menyajikan analisis dan pembahasan kinerja beberapa model Convolutional Neural Network (CNN) yang telah dilatih untuk mendeteksi jenis jerawat. Model yang diuji meliputi MobileNetV2, NASNetMobile, ResNet50V2, DenseNet121, serta EfficientNetB0, dengan jumlah epoch yang bervariasi. Hasil pengujian menunjukkan bahwa ResNet50V2 menampilkan kinerja paling baik, dengan akurasi pelatihan 0,9608 dan akurasi validasi 0,9259, serta loss pelatihan 0,1810 dan loss validasi 0,1984. Model MobileNetV2, NASNetMobile, dan DenseNet121 menunjukkan akurasi dan loss yang cukup baik, namun masih berada di bawah ResNet50V2. Sementara itu, EfficientNetB0 tidak mencapai hasil optimal karena hanya dapat dilatih hingga 6 epoch, menghasilkan akurasi pelatihan dan validasi sebesar 0,2222, serta loss pelatihan 1,6133 dan loss validasi 1,6055.

Tabel 2 menyajikan ringkasan perbandingan kinerja kelima model berdasarkan nilai akurasi (Train Acc, Val Acc) dan loss (Train Loss, Val Loss). Semakin rendah nilai loss, semakin baik kemampuan model dalam memprediksi secara akurat. Begitu pula, semakin tinggi nilai akurasi, semakin efektif model dalam mengenali pola pada data pelatihan dan data validasi. Model dengan performa terbaik ditandai dengan penekanan khusus pada tabel, mempermudah pembaca dalam mengidentifikasi model yang paling direkomendasikan untuk diimplementasikan.

Tabel 2. Komparasi Akurasi tiap model CNN

Model	Train Loss	Train Acc	Val Loss	Val Acc
MobileNetV2	0.24	0.93	0.44	0.81
EfficientNetB0	1.63	0.22	1.60	0.22
NASNetMobile	0.44	0.87	0.59	0.79
DenseNet-121	0.67	0.75	0.53	0.81
ResNet50V2	0.18	0.96	0.19	0.92

Berdasarkan Tabel 2, model ResNet50V2 menunjukkan kinerja terbaik pada sejumlah metrik evaluasi. Model ini memiliki nilai akurasi validasi tertinggi dengan Val Acc sebesar 0,92, serta nilai

kehilangan validasi (Val Loss) terendah, yaitu 0,19. Dengan demikian, dapat disimpulkan bahwa ResNet50V2 merupakan model paling unggul dalam hal performa dan kemampuan klasifikasi, karena mampu memprediksi dengan akurasi tinggi pada dataset yang digunakan dalam penelitian ini. Untuk mengevaluasi hasil yang diperoleh, digunakan matriks kebingungan (*confusion matrix*) yang melibatkan pengukuran akurasi, presisi, recall, dan f1-score. *Confusion Matrix* menggambarkan hasil klasifikasi pembelajaran mesin melalui empat variabel utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

Akurasi: Akurasi mengukur tingkat kesesuaian keseluruhan prediksi model dibandingkan dengan data aktual.

:

$$Akurasi = \frac{TP + TN}{TP + FP + TN + FN}$$

Presisi: Presisi mengukur ketepatan model dalam memprediksi label positif, yaitu seberapa banyak prediksi positif yang benar-benar positif:

$$Presisi = \frac{TP}{TP + FP}$$

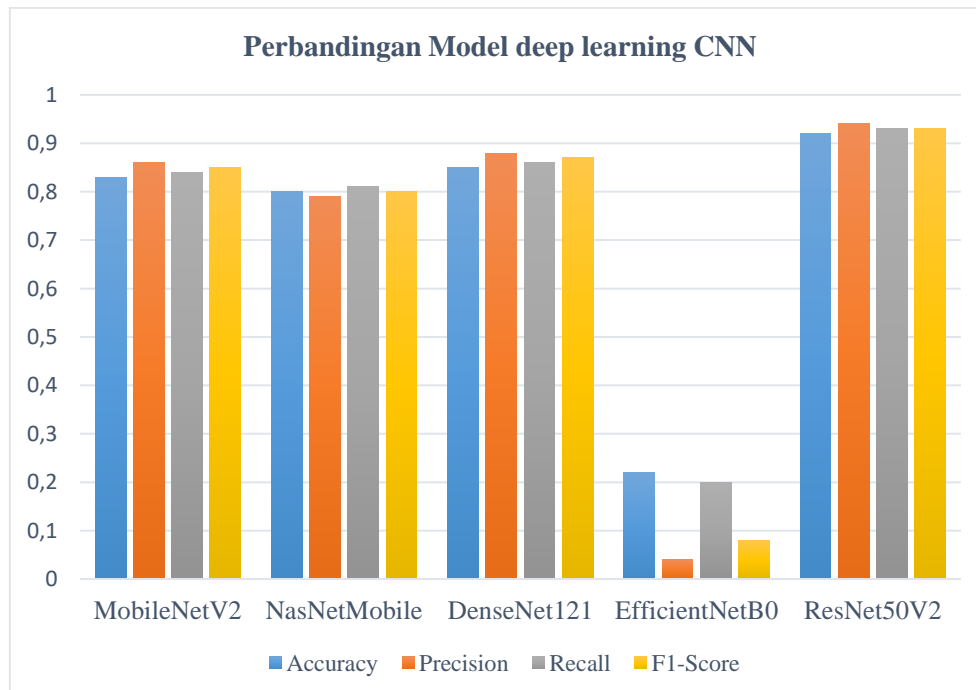
Recall: mengukur seberapa banyak prediksi benar (*True Positive*) yang dapat ditangkap model dari keseluruhan data positif sebenarnya:

$$Recall = \frac{TP}{TP + FN}$$

F1-Score: merupakan ukuran gabungan dari presisi dan recall, yang memperhitungkan kelemahan keduanya:

$$F1 - Score = 2 \times \frac{presisi \times recall}{presisi + recall}$$

Tabel 3 memuat informasi mengenai hasil pengujian model, dengan penanda cetak tebal untuk menunjukkan nilai terbaik yang diperoleh. Skor pada setiap model ditentukan berdasarkan bobot terbaik yang dicapai selama pengujian menggunakan dataset serta analisis matriks kebingungan. Saat pengujian dilakukan, ResNet50V2 memperlihatkan kinerja lebih unggul dalam hal akurasi, presisi, recall, dan f1-score.

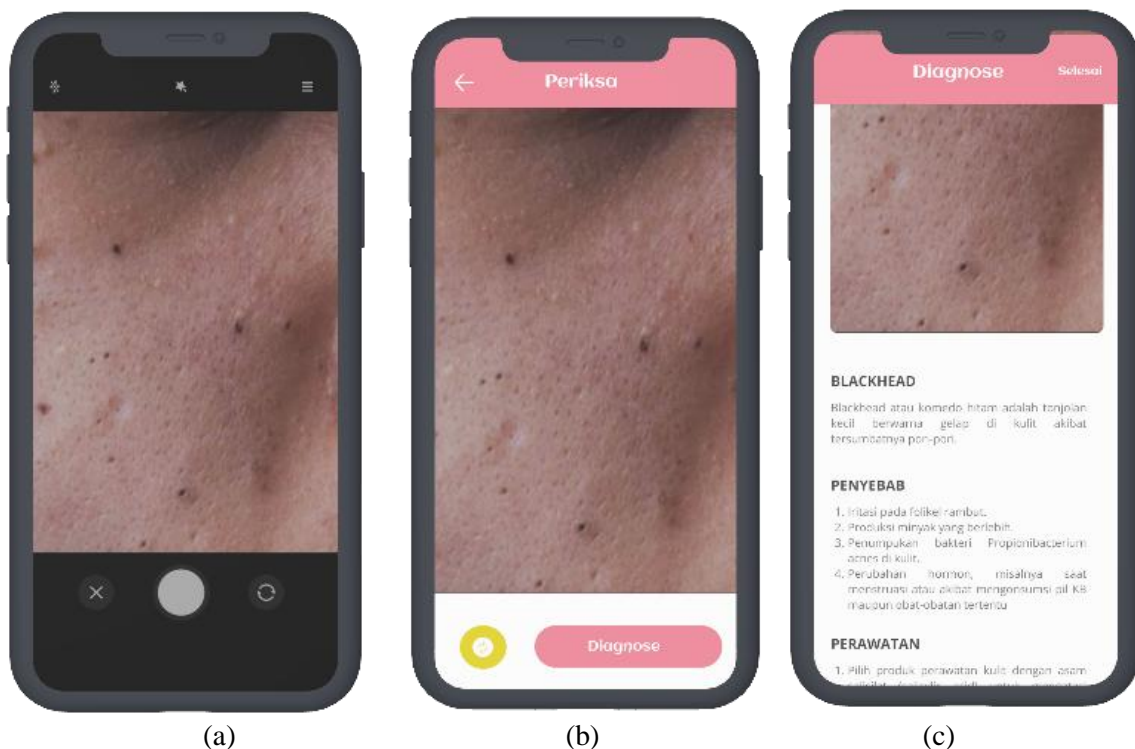


Gambar 5 Perbandingan model deep learning CNN.

Tabel 3. Nilai Akurasi, Presisi, Recall dan F1-Score beberapa model *deep learning* CNN.

	Acc	Precision	Recall	F1-Score
MobileNetV2	0.83	0.86	0.84	0.85
NASNetMobile	0.80	0.79	0.81	0.80
DenseNet-121	0.85	0.88	0.86	0.87
EfficientNetB0	0.22	0.04	0.20	0.08
ResNet50V2	0.92	0.94	0.93	0.93

Grafik perbandingan akurasi, presisi, recall, dan F1-score dapat dilihat pada Gambar 5. Berdasarkan hasil yang ditampilkan dalam Tabel 3 dan Gambar 5, ResNet50V2 memperlihatkan kinerja yang unggul dibandingkan model lainnya, dengan skor tertinggi pada akurasi, presisi, recall, dan F1-score. Model ResNet50V2 mencapai akurasi sebesar 0,92, presisi 0,94, recall 0,93, dan F1-score 0,93. Hal ini menunjukkan bahwa struktur ResNet50V2 mampu mengidentifikasi serta mengklasifikasikan jerawat secara efektif. Setelah model terbaik dipilih, model tersebut diekstraksi ke dalam format TensorFlow Lite. TensorFlow Lite merupakan kerangka kerja TensorFlow yang dioptimalkan khusus untuk perangkat bergerak serta perangkat komputasi dengan daya terbatas. Dengan mengonversi model ke format TensorFlow Lite, model tersebut dapat diintegrasikan ke dalam aplikasi Android agar dapat melakukan pemrosesan citra atau data visual secara efisien pada perangkat. Halaman hasil deteksi dengan menggunakan model MobileNet dapat dilihat pada Gambar 6.



Gambar 6 Deteksi jerawat dan diagnose perawatan pada aplikasi android

Terdapat dua opsi untuk mengunggah citra, yakni melalui kamera secara langsung atau mengimpor dari galeri. Gambar 6(a) menampilkan proses pengambilan foto menggunakan kamera, sedangkan Gambar 6(b) menampilkan citra yang dipilih dari galeri. Ketika tombol “diagnose” diklik, sistem akan menampilkan animasi seperti diperlihatkan pada Gambar 10(d). Hasil deteksi beserta rekomendasi perawatan dapat dilihat pada Gambar 10(e).

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sebuah aplikasi seluler baru yang memanfaatkan metode Convolutional Neural Network (CNN) dengan model ResNet50V2. Lima model telah dikaji, yaitu MobileNetV2, NASNetMobile, ResNet50V2, DenseNet121, dan EfficientNetB0. Model ResNet50V2 dipilih karena menghasilkan tingkat akurasi tertinggi (0,92) serta nilai kesalahan (loss) terendah (0,19). Pengguna dapat memanfaatkan aplikasi ini secara real-time dengan hanya mengambil foto atau memilih citra yang sudah tersedia pada perangkat, sehingga aplikasi dapat secara otomatis mendeteksi jenis jerawat.

Ke depannya, kami berencana untuk mengumpulkan lebih banyak data jerawat serta meningkatkan sumber daya yang tersedia guna mengembangkan arsitektur yang lebih komprehensif. Dengan demikian, sistem ini dapat terus ditingkatkan untuk mencapai kinerja yang lebih optimal.

REFERENSI

- [1] the Global Burden of Disease, *the Global Burden of Disease*. 2019. [Online]. Available: https://www.healthdata.org/results/gbd_summaries/2019/acne-vulgaris-level-3-cause
- [2] M. A. Suva, A. M. Patel, N. Sharma, C. Bhattacharya, and R. K. Mangi, "A BRIEF REVIEW ON ACNE VULGARIS: PATHOGENESIS, DIAGNOSIS AND TREATMENT," 2014.
- [3] C. Stamu-O'Brien, M. Jafferany, S. Carniciu, and A. Abdelmaksoud, "Psychodermatology of acne: Psychological aspects and effects of acne vulgaris," *J. Cosmet. Dermatol.*, vol. 20, no. 4, pp. 1080–1083, Apr. 2021, doi: 10.1111/jocd.13765.
- [4] T. Chantharaphaichi, B. Uyyanonvara, C. Sinthanayothin, and A. Nishihara, "Automatic acne detection for medical treatment," in *2015 6th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES)*, Hua-Hin, Phetchaburi, Thailand: IEEE, Mar. 2015, pp. 1–6. doi: 10.1109/ICTEmSys.2015.7110813.
- [5] Tutiani and S. Wati, "Implementation of Convolutional Neural Network (CNN) in Android-Based Acne Detection Applications," in *2022 International Conference on Information Technology Research and Innovation (ICITRI)*, Jakarta, Indonesia: IEEE, Nov. 2022, pp. 151–155. doi: 10.1109/ICITRI56423.2022.9970231.
- [6] N. Pancholi, S. Goel, R. Nijhawan, and S. Gupta, "Classification and Detection of Acne on the Skin using Deep Learning Algorithms," in *2021 19th OITS International Conference on Information Technology (OCIT)*, Bhubaneswar, India: IEEE, Dec. 2021, pp. 110–114. doi: 10.1109/OCIT53463.2021.00032.
- [7] A. R. Prodeep, R. Araf, P. Ray, Md. S. A. Ulubbi, S. N. Ananna, and M. F. Mridha, "Acne and Rosacea Detection from Images using Deep CNN's EfficientNet," in *2022 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)*, Chennai, India: IEEE, Jan. 2022, pp. 1–7. doi: 10.1109/ACCAI53970.2022.9752534.
- [8] C.-L. Chin, G.-R. Wu, T.-C. Weng, Y.-Y. Kang, B.-J. Lin, and H.-F. Chen, "Skin condition detection of smartphone face image using multi-feature decision method," in *2017 IEEE 8th International Conference on Awareness Science and Technology (iCAST)*, Taichung: IEEE, Nov. 2017, pp. 379–382. doi: 10.1109/ICAwST.2017.8256483.
- [9] K. Rashataprucksa, C. Chuangchaichatchavarn, S. Triukose, S. Nitinawarat, M. Pongprutthipan, and K. Piromsopa, "Acne Detection with Deep Neural Networks," in *2020 2nd International Conference on Image Processing and Machine Vision*, Bangkok Thailand: ACM, Aug. 2020, pp. 53–56. doi: 10.1145/3421558.3421566.
- [10] N. Kittigul and B. Uyyanonvara, "Automatic acne detection system for medical treatment progress report," in *2016 7th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES)*, Bangkok, Thailand: IEEE, Mar. 2016, pp. 41–44. doi: 10.1109/ICTEmSys.2016.7467119.
- [11] M. S. Junayed *et al.*, "AcneNet - A Deep CNN Based Classification Approach for Acne Classes," in *2019 12th International Conference on Information & Communication Technology and System (ICTS)*, Surabaya, Indonesia: IEEE, Jul. 2019, pp. 203–208. doi: 10.1109/ICTS.2019.8850935.