

Optimization of skin cancer detection to improve accuracy with the application of efficient convolutional neural network and efficientnetb2 models

Optimasi deteksi kanker kulit dalam meningkatkan keakuratan dengan penerapan efisien convolutional neural network dan model efficientnetb2

Muhammad Wigig Purbandanu¹, Rizky Yanuarta², Arif Kurniawan³, Muhammad Munsarif⁴

¹Program Studi Informatika, Fakultas Teknik Universitas Muhammadiyah Semarang, Semarang, Indonesia

²Program Studi Informasi, Fakultas Teknik, Universitas Muhammadiyah Semarang, Semarang, Indonesia

³Program Studi Informatika, Fakultas Teknik Universitas Muhammadiyah Semarang, Semarang, Indonesia

Info Artikel

Riwayat Artikel:

Diterima 14, Desember, 2024
Perbaikan 06, Januari, 2025
Disetujui 30, Januari, 2025

Keywords:

Penyakit
Kanker kulit
Klasifikasi
CNN
EfficientNetB2

ABSTRAK

Kanker kulit, terkait paparan sinar ultraviolet, dapat disebabkan oleh mutasi genetik pada sel kulit. Faktor risiko meliputi riwayat keluarga, kulit putih, tahi lalat, imunitas lemah, dan solar keratosis. Diagnosis melibatkan pemeriksaan kulit dan biopsi. Studi terdahulu menggunakan Convolutional Neural Network (CNN) berhasil mengklasifikasikan kanker kulit dengan akurasi hingga 99%. Metode ini efektif dalam deteksi dan klasifikasi penyakit kulit. Proses pengembangan model klasifikasi gambar melibatkan langkah-langkah terstruktur. Dataset dibagi menjadi pelatihan, validasi, pengujian. Augmentasi data dilakukan dengan ImageDataGenerator untuk memperkaya dataset. Model CNN (EfficientNetB2) disesuaikan, dilatih selama 50 epochs. Evaluasi model data pengujian, metrik seperti loss, akurasi, precision, recall, dan F1-score. Visualisasi Classification Reports, Confusion Matrix. Keseluruhan proses memastikan analisis mendalam terhadap performa dan fokus perhatian model pada prediksi. Studi menggunakan data sekunder Kaggle "HAM10000 Preprocessed Data" dengan 11644 data dan tiga atribut, menunjukkan variasi sebelum normalisasi. Model CNN mencapai puncak pada epoch ke-8 dengan akurasi 86%, tetapi ada risiko overfitting. Evaluation menggunakan Classification Report dan Confusion Matrix memberikan detail kinerja model pada setiap kelas kanker kulit, mendukung diagnosis dan penanganan. Artikel ini menyoroti dampak positif penggunaan Model EfficientNetB2 pada deteksi kanker kulit melalui Convolutional Neural Network (CNN) efisien. Model ini optimal dalam ukuran dan struktur, menghasilkan representasi fitur superior. Evaluasi termasuk Classification Report dan Confusion Matrix menunjukkan keunggulan model dalam mengklasifikasikan jenis kanker kulit, khususnya pada kelas "akiec" dan "bcc", dengan akurasi tinggi, meningkatkan performa deteksi secara signifikan.

ABSTRACT

Skin cancer, associated with ultraviolet exposure, can result from genetic mutations in skin cells. Risk factors include family history, fair skin, moles, weakened immunity, and solar keratosis. Diagnosis involves skin examination and biopsy. Previous studies using Convolutional Neural Networks (CNNs) successfully classified skin cancer with up to 99% accuracy. This method is effective in detecting and classifying skin diseases. The image classification model development process involves structured steps. The dataset is divided into training, validation, and testing sets. Data augmentation is performed with ImageDataGenerator to enrich the dataset. The CNN model (EfficientNetB2) is customized and trained for 50 epochs. Evaluation of the test data includes metrics such as loss, accuracy, precision, recall, and F1-

score. Visualization of Classification Reports and Confusion Matrix ensures in-depth analysis of model performance and focuses attention on predictions. The study uses Kaggle's "HAM10000 Preprocessed Data" with 11,644 data and three attributes, showing variations before normalization. The CNN model peaks at the 8th epoch with 86% accuracy, but there is a risk of overfitting. Evaluation using Classification Report and Confusion Matrix provides detailed insight into the model's performance on each skin cancer class, supporting diagnosis and management. This article highlights the positive impact of using the EfficientNetB2 model in skin cancer detection through an efficient Convolutional Neural Network (CNN). The model's

Ini adalah artikel akses terbuka di bawah lisensi CC BY-SA.



Penulis Korespondensi:

Arif Kurniawan

Program Studi Informatika, Fakultas Teknik, Universitas Muhammadiyah Semarang Universitas Muhammadiyah Semarang

Jl. Kedungmundu No. 18, Semarang, Jawa Tengah, Indonesia

Email: wigipurbanda@gmail.com

1. PENDAHULUAN

Kanker kulit adalah jenis kanker yang muncul pada jaringan kulit. Munculnya kondisi ini ditandai dengan terjadinya perubahan pada kulit, seperti terdapat benjolan, tahi lalat, atau bercak yang bentuk dan ukurannya tidak normal. Kanker kulit diyakini terjadi karena paparan sinar ultraviolet yang berasal dari matahari. Paparan sinar tersebut dapat memicu terjadinya kerusakan sel di kulit sehingga berujung pada terjadinya kanker kulit. Kanker kulit disebabkan oleh mutasi atau perubahan genetik yang terjadi pada sel kulit. Penyebab perubahan tersebut belum dapat diketahui, tetapi dugaan kuat terjadi karena paparan sinar matahari berlebihan. Sinar ultraviolet bisa mengakibatkan kerusakan kulit dan memicu pertumbuhan abnormal pada sel kulit. Inilah yang selanjutnya meningkatkan potensi kanker.

Selain itu, masih ada beberapa kondisi lainnya yang turut berperan dalam meningkatkan risiko seseorang mengalami kanker kulit yang pertama faktor internal, yaitu Ada Riwayat Kanker Kulit dalam Keluarga, Pemilik Kulit Putih, Adanya Tahi Lalat, Imunitas Tubuh yang Lemah, Munculnya Solar Keratosis. Sementara itu, beberapa faktor eksternal yang meningkatkan risiko terjadinya kanker kulit yaitu Paparan Cahaya Matahari, Paparan Radiasi, Paparan Senyawa atau Bahan Kimia [1].

Diagnosis kanker kulit juga melalui proses yang lama, Guna mendapatkan diagnosis yang lebih akurat, dokter akan melakukan pemeriksaan pada kulit untuk mengetahui kelainan yang terjadi. Pemeriksaan dilakukan terhadap ukuran, bentuk, tekstur, dan warna kulit. Melalui pemeriksaan ini, dokter dapat menyimpulkan apakah perubahan yang terjadi memang disebabkan karena kanker atau adanya kondisi kesehatan lainnya. Selanjutnya, dokter juga melakukan biopsi kulit. Prosedur ini dilakukan dengan mengambil sampel dari jaringan kulit dan dilakukan pemeriksaan di laboratorium. Apabila masalah kulit yang terjadi memang disebabkan karena kanker, dokter menentukan stadium atau tingkat keparahan kanker kulit yang terjadi. Jika memang diperlukan, dokter dapat melakukan pemeriksaan penunjang lainnya, seperti MRI, CT scan, atau biopsi kelenjar getah bening untuk mengetahui penyebaran dari sel kanker [2].

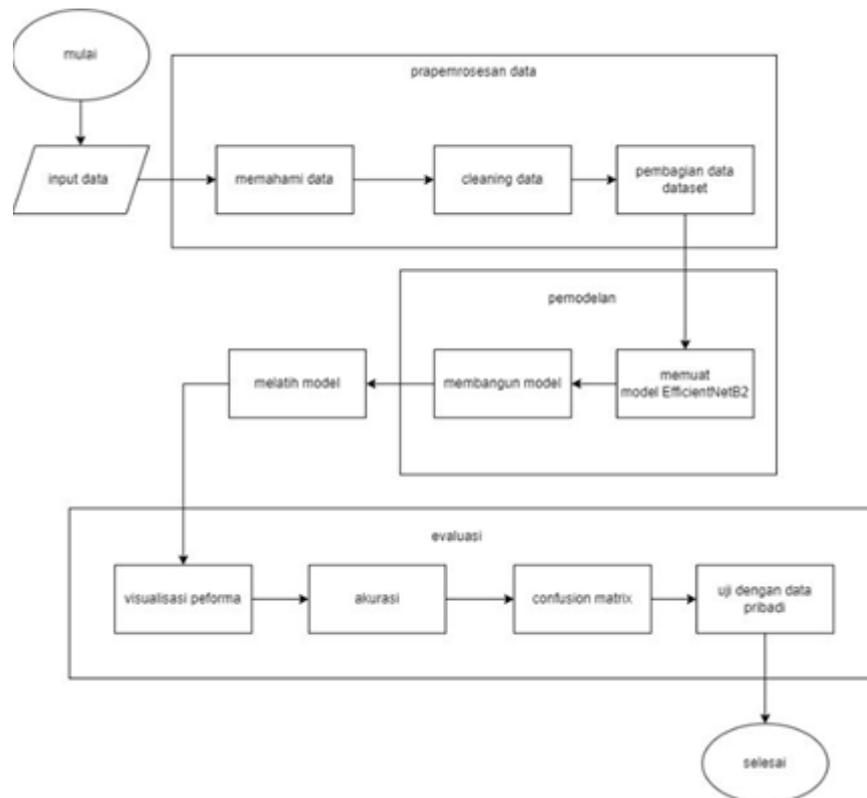
Telah terdapat beberapa penelitian terdahulu mengenai klasifikasi untuk kanker kulit menggunakan Convolutional Neural Network (CNN). Berdasarkan penelitian yang dilakukan oleh [3] menguji dengan membandingkan algoritma dan dermatologis yang membedakan keratinocyte carcinoma versus tumor seborrheic keratosis dan malignant melanoma versus benign nevus. Penulis menggunakan arsitektur Convolutional Neural Network (CNN) GoogleNet Inception V3 yang telah dilatih sebelumnya pada sekitar 1,28 juta gambar (1.000 kategori objek) dari Tantangan Pengenalan Visual Skala Besar ImageNet 2014. Penelitian tersebut berhasil mencapai akurasi sebesar 93,9%. Penelitian selanjutnya oleh [4] melakukan klasifikasi citra kanker kulit berdasarkan tingkat keganasan kanker pada melanosit menggunakan Deep Convolutional Neural Network (DCNN).

Penelitian tersebut menggunakan 1500 citra dengan tiga kategori yaitu nevus, melanoma in situ dan malignant melanoma. Akurasi yang didapat berdasar penelitian adalah sebesar 84%. Selanjutnya penelitian oleh [5] yakni menggunakan dua metode untuk mendeteksi dini kanker kulit, yaitu deteksi dengan klasifikasi

secara regresi dan metode Convolutional Neural Network (CNN). Akurasi deteksi dengan ekstraksi fitur dan regresi k-NN sebesar 75% dengan true positive rate (precision) sebesar 85% dan true negative rate (specificity) sebesar 72%. Sementara, akurasi yang dihasilkan dengan menggunakan CNN adalah sebesar 76,56%. Kemudian penelitian berikutnya oleh [2] mengklasifikasi kanker kulit menjadi empat kelas menggunakan metode CNN dengan 3 hidden layer memperoleh hasil akurasi sebesar 99% dengan loss sebesar 0,0346

2. METODE

2.1. Arsitektur Model



Gambar. 1. Arsitektur Model

Dalam pengembangan model klasifikasi gambar, langkah-langkah terstruktur dan rinci memegang peran krusial. Proses dimulai dengan Preprocessing Data, di mana dataset dibagi menjadi tiga bagian (pelatihan, validasi, dan pengujian) menggunakan metode `train_test_split` dari library `sklearn`. Penggunaan alat bantu seperti `ImageDataGenerator` dan `flow_from_dataframe` dari TensorFlow membantu mengubah dataset dari format DataFrame menjadi format yang dapat digunakan oleh model. Langkah selanjutnya melibatkan Augmentasi Data dengan `ImageDataGenerator`, yang memperluas dataset pelatihan melalui operasi seperti `resizing`, `flip horizontal`, `rotasi`, dan penyesuaian kontras untuk memperkaya informasi yang dapat dipelajari oleh model.

Proses Training the Model dimulai dengan memuat model CNN (EfficientNetB2) yang telah dilatih sebelumnya dengan bobot dari dataset ImageNet. Penyesuaian dilakukan pada arsitektur model dengan menambahkan layer Dense, Dropout, dan output layer dengan fungsi aktivasi softmax sesuai dengan jumlah kelas yang diinginkan. Setelah kompilasi menggunakan optimizer Adam, loss function `categorical_crossentropy`, dan metrik akurasi, model dilatih dengan data pelatihan dan validasi selama 50 epochs dengan bantuan callback seperti `EarlyStopping` dan `ReduceLROnPlateau`.

Langkah berikutnya adalah Model Evaluation, di mana model dievaluasi menggunakan data pengujian untuk mendapatkan nilai loss, akurasi, serta metrik evaluasi lainnya seperti precision, recall, dan F1-score menggunakan `classification_report` dari `sklearn`. Dilanjutkan dengan Making Predictions on the Test Data, di mana model melakukan prediksi pada data pengujian untuk menghasilkan label prediksi yang kemudian diubah kembali dari bentuk indeks menjadi nama kelas yang sesuai untuk perbandingan dengan label sebenarnya.

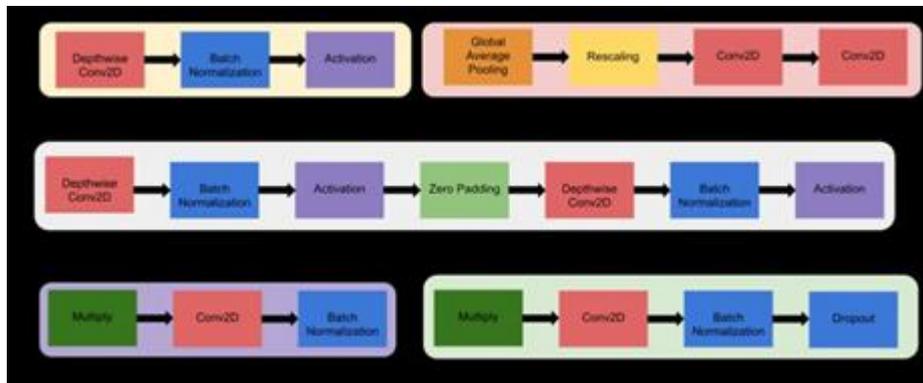
Proses akhir melibatkan plotting Classification Reports dan Confusion Matrix, yang menampilkan laporan klasifikasi dengan metrik evaluasi untuk setiap kelas dan visualisasi matriks konfusi untuk

mengidentifikasi di mana model membuat kesalahan. Keseluruhan, langkah-langkah ini membentuk proses yang terstruktur dalam pengembangan dan evaluasi model klasifikasi gambar, memungkinkan analisis mendalam terhadap performa model, ketepatan klasifikasi, dan pemahaman terhadap aspek mana dari gambar yang menjadi fokus perhatian model saat membuat prediksi.

2.2. Convolutional Neural Network

Proses pelatihan dan pengujian menggunakan metode Convolutional Neural Network (CNN) melibatkan pembagian dataset yang telah dikumpulkan menjadi dua bagian, yaitu data pelatihan dan data pengujian. Tujuannya adalah untuk menghasilkan hasil yang optimal, yang dicapai melalui proses pelatihan dan pengujian. Setelah proses pelatihan selesai, langkah berikutnya adalah menghitung nilai kerugian (loss) dan akurasi dari hasil pengujian. Akurasi dari data pengujian memberikan gambaran tentang kinerja model terhadap data yang belum pernah dilihat sebelumnya. Penentuan jumlah epoch yang optimal dilakukan selama satu sesi pengujian untuk mendapatkan tingkat kesalahan yang rendah dan hasil yang baik. Setelah data dilabeli dan dibagi menjadi data pelatihan dan pengujian, langkah berikutnya adalah melatih dataset menggunakan algoritma Convolutional Neural Network (CNN) dengan merancang arsitektur jaringan untuk mencapai tingkat akurasi yang diinginkan [6].

2.3. EfficientNetB2



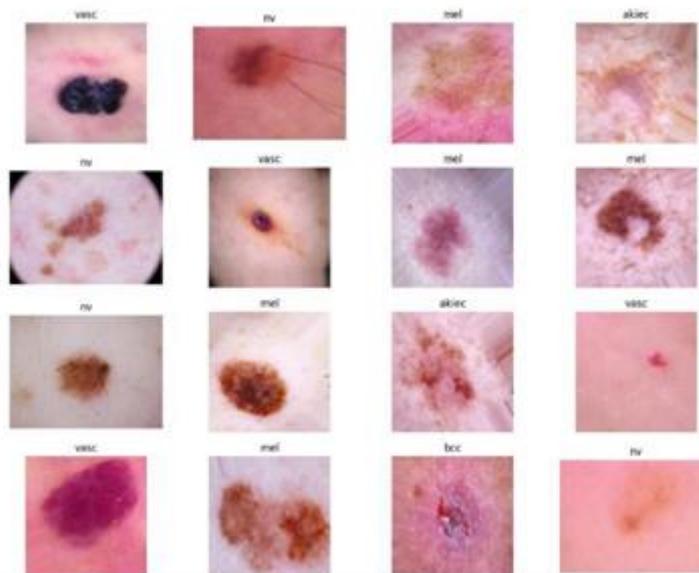
Gambar. 2. EfficientNetB2 modules description

EfficientNetB2 adalah varian yang signifikan dari keluarga EfficientNet, suatu arsitektur jaringan saraf tiruan yang dikenal karena keefisienannya dalam memanfaatkan sumber daya komputasi. Dikembangkan oleh tim peneliti Google pada tahun 2019, EfficientNetB2 menonjol dengan ukuran modelnya yang berada di tengah-tengah dalam keluarga EfficientNet. Dengan peningkatan kedalaman dan lebar, model ini memperoleh kapasitas representasi yang lebih baik dan kemampuan belajar yang ditingkatkan. Menggunakan konsep "Compound Scaling", EfficientNetB2 mengukur pengaruh perubahan kedalaman, lebar, dan resolusi pada kinerja keseluruhan. Pre-trained pada dataset besar seperti ImageNet, varian ini dapat mengekstrak fitur umum yang dapat diadaptasi untuk berbagai tugas pengenalan gambar atau transfer learning. Efisiensi tinggi EfficientNetB2, yang dicapai dengan jumlah parameter yang relatif lebih sedikit, membuatnya cocok untuk penggunaan dalam lingkungan dengan sumber daya komputasi terbatas. Sebagai pilihan yang baik untuk tugas pengenalan gambar, EfficientNetB2 memberikan keseimbangan optimal antara performa dan efisiensi [7,8].

3. HASIL DAN PEMBAHASAN

3.1. Dataset

Data yang digunakan untuk studi kasus ini yaitu data sekunder yang diperoleh dari Kaggle (HAM10000 Preprocessed Data (kaggle.com)). dengan data yang berjudul HAM10000 skin disease dataset, yang memiliki total data 11644 dan memiliki 3 atribut yang terdiri dari imgpath, labels, encoded_labels, data ini juga dibagi menjadi enam yaitu mel 2362, nv 2146, akiec 1824, vasc 1563, df 1344, bcc 1254, bkl 1151 berikut adalah dataset dapat dilihat di Gambar 3.



Gambar. 3. Dataset

3.2. Preprocessing Data

Tabel. 1. Prapemrosesan Data

<u>Jumlah File Gambar</u>	<u>Jumlah Kelas</u>
9315	7
1397	7
932	7

Prapemrosesan Data memberikan pandangan awal tentang karakteristik dataset sebelum dilakukan pemrosesan lebih lanjut. Dengan jumlah file gambar sebanyak 9315, distribusi dataset ini terdiri dari tujuh kelas yang berbeda. Setiap kelas memiliki jumlah gambar yang bervariasi, seperti terlihat pada baris kedua dengan 1397 file gambar dan pada baris ketiga dengan 932 file gambar. Informasi ini menggambarkan variasi dan distribusi data dalam dataset, yang menjadi dasar penting untuk pemrosesan lebih lanjut, termasuk normalisasi, augmentasi, atau langkah-langkah pra-pemrosesan lainnya untuk mempersiapkan data sebelum diberikan kepada model klasifikasi. Perhitungan dan analisis lebih lanjut pada tahap ini dapat membantu mengidentifikasi potensi ketidakseimbangan kelas atau kebutuhan strategi pra-pemrosesan tertentu guna meningkatkan kualitas dan keberlanjutan model klasifikasi kanker kulit.

3.3. Evaluasi model

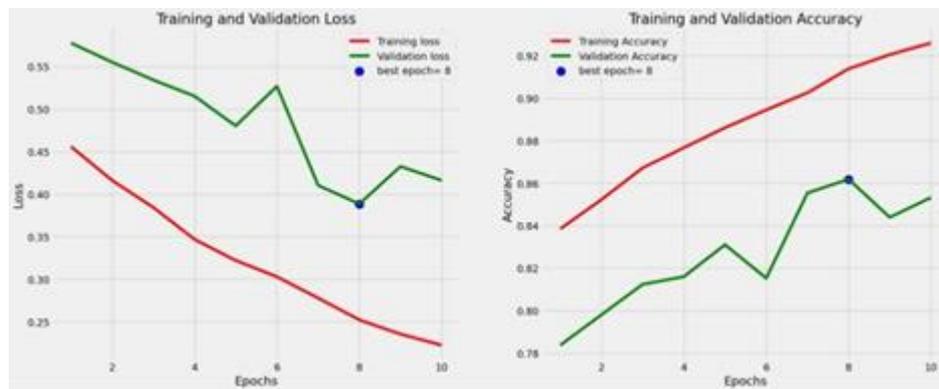
3.3.1. Visualisasi Kurva

Grafik Loss Pelatihan dan Validasi memberikan pandangan mendalam tentang bagaimana model mengalami perubahan dalam hal kesalahan selama proses pelatihan. Garis merah yang merepresentasikan loss pelatihan dan garis hijau yang melambangkan loss validasi saling berinteraksi, membentuk suatu narasi yang memperlihatkan tren dan dinamika kompleks. Penurunan signifikan pada loss validasi, mencapai titik terendahnya pada epoch ke-8, menandakan fase di mana model mencapai optimalitas. Namun, peningkatan selanjutnya pada loss validasi setelah titik tersebut menggambarkan potensi terjadinya overfitting, yaitu kondisi di mana model menjadi terlalu sesuai dengan data pelatihan, yang dapat merugikan performa pada data baru yang belum pernah dilihat sebelumnya.

Sementara itu, Grafik Akurasi Pelatihan dan Validasi menambah dimensi analisis dengan memberikan pemahaman tentang bagaimana ketepatan model berkembang seiring waktu. Kurva merah yang mencerminkan akurasi pelatihan dan kurva hijau yang mencerminkan akurasi validasi menciptakan narasi yang semakin kompleks. Epoch ke-8, di mana terjadi puncak akurasi validasi, menandai puncak performa model. Namun, ketidakberlanjutan peningkatan akurasi validasi setelah epoch tersebut mengindikasikan bahwa model mungkin mulai kehilangan generalitasnya, khususnya dengan adanya kenaikan loss pada data validasi.

Melalui dua grafik ini, kita dapat membaca tidak hanya tentang pencapaian puncak kinerja model pada epoch ke-8, tetapi juga tentang risiko overfitting dan potensi penurunan generalitas model setelah titik tersebut.

Analisis ini menggambarkan kompleksitas dinamika pelatihan model, mengingatkan pada pentingnya pengawasan dan pengelolaan overfitting untuk memastikan generalisasi yang baik pada data yang belum pernah dilihat sebelumnya.



Gambar. 4. Training and Validation Accuracy

3.3.2. Prediksi Data Tes

Hasil output dari DataFrame Predictions mencerminkan prediksi model klasifikasi untuk delapan gambar pertama dalam dataset pengujian. Setiap baris menampilkan informasi yang komprehensif, termasuk nomor indeks gambar, label aktual, nama kelas aktual, label prediksi, nama kelas prediksi, path atau lokasi gambar, dan probabilitas prediksi. Sebagai contoh, pada gambar dengan indeks 0, yang terkait dengan kelas "mel" (melanoma), model berhasil memprediksi kelas yang sama dengan tingkat kepercayaan sekitar 97.17%. Analisis serupa diterapkan pada gambar-gambar lainnya, menyediakan wawasan mendalam tentang kinerja model dalam mengenali dan mengklasifikasikan berbagai jenis gambar pada data uji. Informasi ini penting untuk evaluasi dan peningkatan model, serta memberikan pemahaman yang lebih baik tentang sejauh mana model dapat diandalkan dalam tugas klasifikasi dermatologi.

Tabel. 2. Prediksi Delapan Data Teratas

Image Index	Test Labels	Test Classes	Prediction Labels	Prediction Classes	Path	Prediction Probability
0	0	4	mel	4	/content/drive/MyDrive/data2/data/mel/ 248_603...	0.971704
1	1	0	akiec	0	/content/drive/MyDrive/data2/data/akiec/ 260_2...	0.910902
2	2	6	vasc	6	/content/drive/MyDrive/data2/data/vasc/ 20_876...	0.999527
3	3	4	mel	4	/content/drive/MyDrive/data2/data/mel/ 89_1206...	0.747411
4	4	3	df	3	/content/drive/MyDrive/data2/data/df/ 57_21478...	0.957664
5	5	1	bcc	1	/content/drive/MyDrive/data2/data/bcc/ 365_515...	0.748683
6	6	0	akiec	0	/content/drive/MyDrive/data2/data/akiec/ 185_9...	0.982450
7	7	2	bkl	2	/content/drive/MyDrive/data2/data/bkl/ 448_177...	0.966193

3.3.3. Hasil Klasifikasi Data

Classification Report pada table 3 memberikan insight mendalam tentang kinerja model klasifikasi pada berbagai kelas kanker kulit. Untuk kelas "akiec", model menunjukkan tingkat presisi sekitar 97%, yang mengindikasikan kemampuannya dalam mengidentifikasi kanker kulit jenis ini dengan tingkat akurasi yang tinggi. Namun, recall sekitar 71% menandakan adanya beberapa kasus positif sejati yang mungkin terlewatkan oleh model. Kelas "bcc" juga mendapat evaluasi yang positif, dengan tingkat presisi sekitar 89% dan recall sekitar 80%. Kelas lain seperti "bkl", "df", "mel", "nv", dan "vasc" juga dievaluasi dengan metrik presisi, recall, dan F1-score masing-masing.

Penting untuk dicatat bahwa setiap metrik memberikan pandangan yang berbeda tentang kinerja model. Presisi dan recall memberikan gambaran tentang sejauh mana model mampu mengidentifikasi kelas tertentu tanpa membuat kesalahan yang signifikan. F1-Score, sebagai harmonic mean dari keduanya, memberikan ukuran keseimbangan antara presisi dan recall. Dengan demikian, Classification Report ini membantu peneliti atau praktisi untuk memahami kekuatan dan kelemahan model dalam konteks klasifikasi kanker kulit, memberikan dasar untuk perbaikan dan pengembangan lebih lanjut.

Tabel. 3. Classification Report

Class	Precision	Recall	F1-Score	Support
akiec	0.97	0.71	0.82	167
bcc	0.89	0.80	0.84	91
bkl	0.52	0.78	0.63	78
df	0.97	0.99	0.98	118
mel	0.81	0.82	0.81	179
nv	0.88	0.93	0.90	174
vasc	1.00	0.99	1.00	125

Pada Tabel 4, yang merinci Rata-Rata Presisi, Recall, dan F1-Score, memberikan gambaran komprehensif tentang kinerja keseluruhan model klasifikasi dalam konteks klasifikasi kanker kulit. Pada tingkat makro rata-rata, model mencapai presisi sekitar 88%, recall sekitar 87%, dan F1-Score sekitar 87%. Hasil ini mencerminkan kemampuan model dalam mengatasi berbagai kelas kanker kulit secara keseluruhan. Di sisi lain, pada tingkat berbobot rata-rata, model menunjukkan kinerja yang serupa dengan presisi, recall, dan F1-Score masing-masing sekitar 88%. Nilai-nilai ini mencerminkan keseluruhan kemampuan model dalam menangani kelas-kelas kanker kulit dengan mempertimbangkan distribusi data secara keseluruhan.

Dengan melibatkan Jumlah Data sebanyak 1099, Classification Report ini memberikan pandangan holistik tentang efektivitas model dalam mengklasifikasikan gambar kanker kulit. Rata-rata ini adalah ringkasan yang berharga untuk memahami performa model secara keseluruhan, membantu pemangku kepentingan untuk mengambil keputusan yang terinformasi terkait pengembangan dan peningkatan model klasifikasi kanker kulit.

Tabel. 4. Rata – Rata Presisi, Recall, dan F1-Score

Kategori	Precision	Recall	F1-Score	Jumlah Data
Macro AVG	0.86	0.86	0.85	932
Weighted AVG	0.88	0.86	0.86	932

Di Tabel 5, yang memaparkan nilai akurasi model, memberikan gambaran tentang sejauh mana model berhasil mengklasifikasikan gambar kanker kulit secara benar. Dengan tingkat akurasi sekitar 86%, model mampu dengan efektif mengenali dan membedakan berbagai jenis kanker kulit dalam dataset. Dengan melibatkan 932 data, akurasi ini mencerminkan proporsi keseluruhan prediksi yang benar oleh model terhadap keseluruhan data uji. Hasil ini menyiratkan keandalan model dalam memberikan prediksi yang akurat, yang dapat menjadi informasi krusial dalam konteks diagnosis dan penanganan kanker kulit. Akurasi tinggi ini memberikan keyakinan bahwa model dapat memberikan kontribusi positif dalam mendukung praktisi kesehatan dalam proses identifikasi dan klasifikasi jenis kanker kulit secara otomatis.

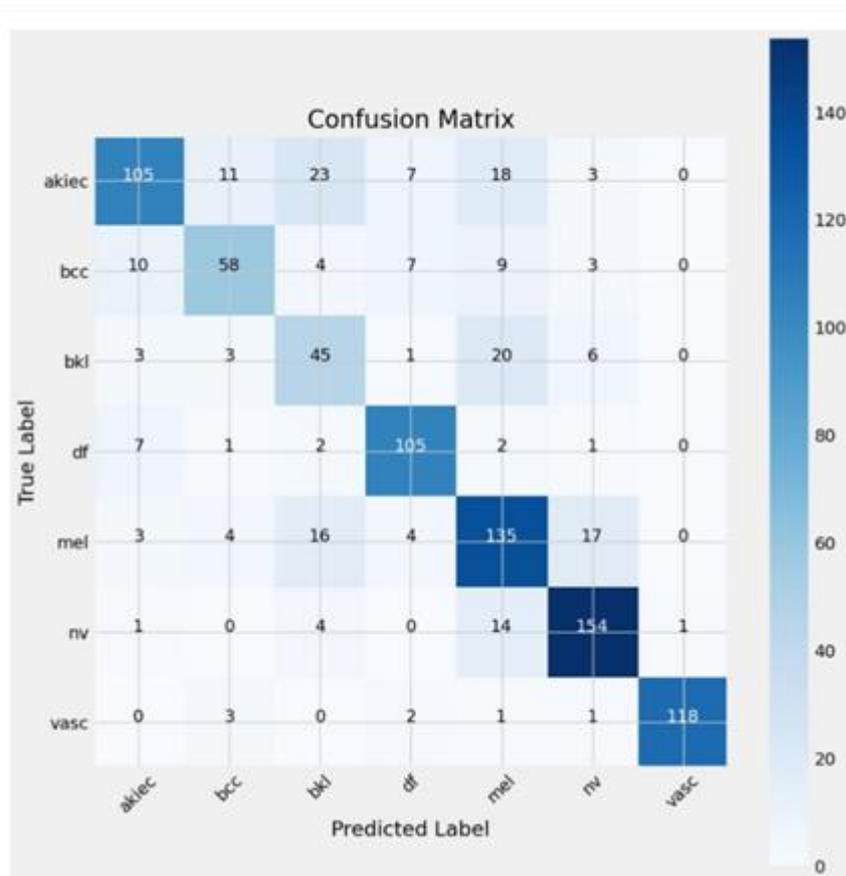
Tabel. 5. Akurasi

Akurasi	Jumlah Data
0.86	932

3.3.4. Matriks Konfusi

Confusion matrix yang telah disajikan pada gambar merupakan alat evaluasi yang sangat informatif untuk menilai performa model klasifikasi. Setiap baris pada matriks merepresentasikan kelas sebenarnya, sementara setiap kolom mencerminkan kelas yang diprediksi oleh model. Angka pada diagonal matriks, seperti 105 untuk 'akiec', 58 untuk 'bcc', dan seterusnya, mencerminkan jumlah prediksi yang benar di mana kelas sebenarnya dan kelas yang diprediksi cocok.

Di sisi lain, elemen di luar diagonal matriks menunjukkan kesalahan yang dibuat oleh model. Sebagai contoh, angka 11 pada baris 'akiec' dan kolom 'bcc' menandakan bahwa ada 11 kasus di mana kelas sebenarnya adalah 'akiec', tetapi model memprediksinya sebagai 'bcc'. Dengan demikian, confusion matrix memberikan gambaran yang terperinci tentang di mana model membuat kesalahan dan sejauh mana kinerjanya untuk setiap kelas. Secara keseluruhan, hasil menunjukkan bahwa model memiliki performa yang baik dalam memprediksi beberapa kelas seperti 'akiec' dan 'bcc', namun ada potensi untuk peningkatan performa khususnya pada kelas 'bkl'.



Gambar. 5. Confussion Matrix

4. KESIMPULAN

Dalam artikel ini mengungkapkan dampak positif penggunaan Model EfficientNetB2 dalam meningkatkan keakuratan deteksi kanker kulit. Dengan menerapkan Convolutional Neural Network (CNN) yang efisien, model mampu mengatasi kompleksitas klasifikasi kanker kulit dengan lebih baik.

Efisiensi Model EfficientNetB2 mencapai titik puncaknya melalui ukuran dan struktur yang optimal, menghasilkan representasi fitur yang lebih baik dari gambar kanker kulit. Hasil evaluasi yang tercakup dalam Classification Report, Rata-Rata Presisi, Recall, F1-Score, dan Akurasi, menyoroti keunggulan model ini dalam mengenali berbagai jenis kanker kulit. Terlihat bahwa model EfficientNetB2 secara signifikan meningkatkan performa, terutama dalam kelas-kelas tertentu seperti 'akiec' dan 'bcc', di mana presisi dan recall mencapai tingkat yang memuaskan.

Secara khusus, hasil dari Confusion Matrix menunjukkan bahwa Model EfficientNetB2 secara efektif mengurangi kesalahan prediksi, memperlihatkan kemampuannya untuk dengan akurat mengklasifikasikan gambar kanker kulit. Dengan demikian, penerapan EfficientNetB2 memberikan kontribusi positif dalam optimasi deteksi kanker kulit, menghasilkan hasil yang andal dan meningkatkan keakuratan secara signifikan. Pada akhirnya, artikel ini memberikan bukti bahwa pemilihan model yang tepat, seperti EfficientNetB2, dapat memainkan peran kunci dalam mencapai deteksi kanker kulit yang lebih efisien dan andal.

REFERENSI

- [1] Hendaria, M. P., Asmarajaya, A., & Maliawan, S. (2013). Kanker kulit. Universitas Udayana.
- [2] Fu'adah, Y. N., Pratiwi, N. C., Pramudito, M. A., & Ibrahim, N. (2020). Convolutional neural network (CNN) for automatic skin cancer classification system. *IOP Conference Series: Materials Science and Engineering*, 982(1), 0–10. <https://doi.org/10.1088/1757-899X/982/1/012005>
- [3] Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542 (7639), 115–118.
- [4] Munthe, T. L. D. (2018). Klasifikasi citra kanker kulit berdasarkan tingkat keganasan kanker pada melanosit menggunakan deep convolutional neural network (DCNN). *Repositori Institusi Universitas Sumatera Utara (RI-USU)*, 44–48.
- [5] Savera, T. R., Suryawan, W. H., & Setiawan, A. W. (2020). Deteksi dini kanker kulit menggunakan K-Nn dan early detection of skin cancer using K-Nn and convolutional. *7 Klasifikasi Kanker Kulit Menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16 ELKOMIKA – 457* (2), 373–378. <https://doi.org/10.25126/jtiik.202072602>
- [6] F. F. Maulana and N. Rochmawati, “Klasifikasi Citra Buah Menggunakan Convolutional Neural Network,” *J. Informatics Comput. Sci.*, vol. 01, no. 02, pp. 104–108, 2019.
- [7] Tan, M. and Le, Q. V., 2021. EfficientNetV2: Smaller Model and Faster Training, [online] Available at: <<http://arxiv.org/abs/2104.00298>>.
- [8] Tan, M., Pang, R., and Le, Q. V. Efficientdet: Scalable and efficient object detection. *CVPR*, 2020
- [9] Albattah, W., Javed, A., Nawaz, M., Masood, M. and Albahli, S., 2022. Artificial Intelligence-Based Drone System for Multiclass Plant Disease Detection Using an Improved Efficient Convolutional Neural Network. *Frontiers in Plant Science*, 13 (June). <https://doi.org/10.3389/fpls.2022.808380>.
- [10] Bello, I. Lambdanetworks: Modeling long-range interactions without attention. *ICLR*, 2021.
- [11] Bello, I., Fedus, W., Du, X., Cubuk, E. D., Srinivas, A., Lin, T.-Y., Shlens, J., and Zoph, B. Revisiting resnets: Improved training and scaling strategies. *arXiv preprint arXiv:2103.07579*, 2021..
- [12] Brock, A., De, S., Smith, S. L., and Simonyan, K. Highperformance large-scale image recognition without normalization. *arXiv preprint arXiv:2102.06171*, 2021.
- [13] Akram, A., Fayakun, K., & Ramza, H. (2023). Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network. *Building of Informatics, Technology and Science (BITS)*, 5(2). <https://doi.org/10.47065/bits.v5i2.4063>
- [14] M. I. Mardiyah, “Implementasi Deep Learning untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (CNN) Pada Citra Kebun dan Sawah,” Universitas Islam Indonesia, 2020.
- [15] K. H. Mahmud, Adiwijaya, and S. Al Faraby, “Klasifikasi Citra Multi-Kelas Menggunakan Convolutional Neural Network,” in *e-Proceeding of Engineering*, 2019, vol. 6, no. 1, pp. 2127–2136
- [16] D. Husen, K. Kusrini, dan K. Kusnawi, “Deteksi Hama pada Daun Apel Menggunakan Algoritma Convolutional Neural Network,” *J. Media Inform. Budidarma*, vol. 6, no. 4, hal. 2103–2110, 2022, doi: 10.30865/mib.v6i4.4667.
- [17] R. Shinta, Jasril, M. Irsyad, F. Yanto, dan S. Sanjaya, “Klasifikasi Citra Penyakit Daun Tanaman Padi Menggunakan CNN dengan Arsitektur VGG-19,” *J. Sains dan Inform.*, vol. 9, no. 1, hal. 37–45, 2023, doi: 10.22216/jsi.v9i1.2175.
- [18] D. Irfansyah, M. Mustikasari, dan A. Suroso, “Arsitektur Convolutional Neural Network (CNN) Alexnet untuk Klasifikasi Hama pada Citra Daun Tanaman Kopi,” *J. Inform. J. Pengemb. IT*, vol. 6, no. 2, hal. 87–92, 2021, [Daring]. Tersedia pada: <http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/2802>
- [19] Tan, M. and Le, Q. V. Efficientnet: Rethinking model scaling for convolutional neural networks. *ICML*, 2019a.