

PENDEKATAN TRANSFER LEARNING DAN SMOTE UNTUK KLASIFIKASI KANKER KULIT PADA IMBALANCED DATASET

Lutviana[✉], Purwono, Imam Ahmad Ashari

Informatika, Universitas Harapan Bangsa, Banyumas, Indonesia

Email: luthvianna41@gmail.com

DOI: <https://doi.org/10.46880/jmika.Vol9No2.pp323-331>

ABSTRACT

Early detection is a key factor in reducing skin cancer mortality, conventional methods such as biopsy have limitations in terms of cost and invasiveness. This research applies a deep learning-based approach for skin cancer classification with Convolutional Neural Networks (CNN) model using transfer learning method. 3 CNN architectures namely MobileNetV2, EfficientNetB0, and DenseNet121 are used to evaluate the performance of the model in detecting skin cancer. One of the main challenges in this research is the imbalanced dataset, which can cause bias in classification. The Synthetic Minority Over-Sampling Technique (SMOTE) was applied to improve the representation of minority classes. The dataset used comes from Kaggle and consists of 2,357 images classified into 9 skin cancer categories. The results show that the transfer learning method combined with SMOTE can significantly improve the accuracy of the model, especially in detecting classes with a smaller number of samples. The evaluation was conducted using accuracy, precision, recall, and f1-score metrics. This research is expected to contribute to the development of an artificial intelligence-based skin cancer detection system that is more accurate, efficient, and can be used as a tool for medical personnel in early diagnosis of skin cancer.

Keyword: Skin Cancer, SMOTE, DenseNet121, EfficientNetB0, MobileNetV2.

ABSTRAK

Deteksi dini menjadi faktor kunci dalam mengurangi angka kematian akibat kanker kulit, metode konvensional seperti biopsi memiliki keterbatasan dalam hal biaya dan sifatnya yang invasif. Penelitian ini menerapkan pendekatan berbasis deep learning untuk klasifikasi kanker kulit menggunakan model Convolutional Neural Networks (CNN) dengan metode transfer learning. Tiga arsitektur CNN yaitu MobileNetV2, EfficientNetB0, dan DenseNet121 digunakan untuk mengevaluasi performa model dalam mendeteksi kanker kulit. Salah satu tantangan utama dalam penelitian ini adalah imbalance dataset, yang dapat menyebabkan bias dalam klasifikasi. Teknik Synthetic Minority Over-Sampling Technique (SMOTE) diterapkan guna meningkatkan representasi kelas minoritas. Dataset yang digunakan berasal dari Kaggle dan terdiri dari 2,357 citra yang diklasifikasikan ke dalam 9 kategori kanker kulit. Hasil penelitian menunjukkan bahwa metode transfer learning yang dikombinasikan dengan SMOTE mampu meningkatkan akurasi model secara signifikan, terutama dalam mendeteksi kelas dengan jumlah sampel yang lebih sedikit. Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan f1-score. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi kanker kulit berbasis kecerdasan buatan yang lebih akurat, efisien, dan dapat digunakan sebagai alat bantu bagi tenaga medis dalam diagnosis dini kanker kulit.

Kata Kunci: Kanker Kulit, SMOTE, DenseNet121, EfficientNetB0, MobileNetV2.

PENDAHULUAN

Kanker kulit merupakan salah satu jenis kanker yang paling umum didiagnosis di seluruh dunia, dengan jumlah kasus baru mencapai 1,2 juta pada tahun 2020 (World Health Organization, 2022). Insiden yang terus meningkat menunjukkan bahwa upaya deteksi dini dan pencegahan masih perlu dioptimalkan. Di Indonesia, kanker kulit menempati peringkat ketiga setelah kanker rahim dan kanker payudara, dengan prevalensi sekitar 5,9–7,8% dari semua jenis kanker (Saputro et al.,

2022). Faktor utama yang berkontribusi terhadap perkembangan kanker kulit meliputi paparan sinar ultraviolet, riwayat keluarga, serta daya tahan tubuh yang rendah (Wedayani et al., 2022). Oleh karena itu, deteksi dini menjadi aspek penting dalam mengurangi angka kematian akibat kanker kulit.

Metode konvensional untuk mendiagnosa kanker kulit adalah biopsi, yang meskipun akurat tetapi memiliki keterbatasan seperti biaya yang tinggi dan risiko melukai jaringan kulit pasien. Seiring kemajuan

teknologi, pemanfaatan *Artificial Intelligence* (AI) dalam pengolahan citra medis menjadi alternatif yang menjanjikan untuk diagnosis kanker kulit yang lebih cepat dan non-invasif (Dartiko et al., 2024). *Convolutional Neural Networks* (CNN) telah banyak digunakan dalam klasifikasi citra medis karena kemampuannya dalam mengekstraksi fitur penting secara otomatis dan meningkatkan akurasi diagnosis (Subagio et al., 2024).

Namun, salah satu tantangan utama dalam penerapan CNN untuk klasifikasi kanker kulit adalah *imbalanced dataset*. Model yang dilatih pada *dataset* dengan distribusi kelas yang tidak seimbang cenderung bias terhadap kelas mayoritas, sehingga mengurangi akurasi dalam mengenali kasus kanker yang lebih jarang ditemui (Ramdhana & Pratiwi, 2023). Synthetic Minority Over-sampling Technique (SMOTE) digunakan sebagai teknik penyeimbangan data yang mampu meningkatkan representasi kelas minoritas melalui pembuatan sampel sintetis (Kurniawan & Salam, 2024).

Transfer learning memungkinkan penggunaan model CNN yang telah dilatih sebelumnya pada *dataset* besar untuk diterapkan pada tugas spesifik, sehingga mengurangi kebutuhan data dan waktu pelatihan (Indraswari et al., 2022). Dalam penelitian ini, pendekatan *transfer learning* dikombinasikan dengan SMOTE untuk meningkatkan akurasi klasifikasi kanker kulit pada *dataset* yang tidak seimbang. Arsitektur CNN yang digunakan dalam penelitian ini meliputi MobileNetV2, EfficientNetB0, dan DenseNet121 yang dipilih berdasarkan efisiensi parameter dan performa yang kompetitif dalam klasifikasi citra medis (Duman & Tolan, 2021).

MobileNetV2 adalah model ringan yang menggunakan kombinasi *depthwise separable convolution*, *linear bottleneck*, dan *shortcut connections* antar layer, yang membuat model ini efisien dalam hal ukuran dan kecepatan komputasi (Harahap et al., 2023). DenseNet121 memiliki karakteristik *dense connections* yang menghubungkan setiap layer ke semua layer sebelumnya, sehingga memungkinkan propagasi informasi yang lebih baik dan efisiensi parameter yang lebih tinggi (Awalia & Primajaya, 2022). EfficientNetB0 dikembangkan menggunakan pendekatan *compound scaling*, yang secara proporsional menyeimbangkan kedalaman, lebar, dan resolusi jaringan untuk menghasilkan model yang lebih akurat dan ringan (Sundari et al., 2022).

Penelitian sebelumnya telah banyak memanfaatkan CNN untuk klasifikasi kanker kulit namun masih sedikit yang menggabungkan transfer

learning dengan teknik penyeimbangan data seperti SMOTE, khususnya dalam klasifikasi kanker kulit. Penelitian ini bertujuan untuk mengevaluasi performa model CNN dalam klasifikasi kanker kulit pada *dataset* yang tidak seimbang serta menganalisis efektivitas SMOTE dalam meningkatkan akurasi model. Hasil penelitian ini diharapkan dapat memberikan kontribusi bagi komunitas akademik dan praktisi medis dalam mengembangkan sistem berbasis AI untuk deteksi dini kanker kulit yang lebih akurat dan efisien.

TINJAUAN PUSTAKA

Beberapa penelitian sebelumnya yang relevan dengan topik penelitian telah menjadi dasar penelitian ini. Penelitian Rahman & Ami (2020) menggunakan arsitektur ResNet, DenseNet, dan Xception dengan *transfer learning* untuk klasifikasi lesi kulit pada *dataset* HAM10000 yang terdiri dari 10.015 gambar dalam 7 kelas. *Loss weighting* dan *data augmentation* diterapkan dalam penelitian untuk mengatasi ketidakseimbangan kelas. Hasil penelitian didapatkan *metrik balanced accuracy* mencapai 78.15% untuk ResNet, 81.8% untuk Xception, dan 81.9% untuk DenseNet. Teknik *average ensemble* meningkatkan *balanced accuracy* menjadi 85.3%, dengan *precision* 81% dan *f1-score* 83%.

Penelitian Ali et al. (2022) menggunakan arsitektur EfficientNet B0-B7 dengan *transfer learning* untuk klasifikasi *multiclass* kanker kulit pada *dataset* HAM10000 yang berisi 10.015 citra dalam 7 kelas. *Preprocessing* mencakup pembersihan *noise*, augmentasi data, dan *resizing* citra. Model diuji dengan metrik *precision*, *recall*, *f1-score*, dan ROC-AUC. Hasilnya, EfficientNet B4 menunjukkan performa terbaik dengan *f1-score* 87% dan Top-1 *Accuracy* 87,91%, sementara model lebih kompleks (B6 dan B7) cenderung mengalami *overfitting*.

Penelitian Bechelli & Delhomelle (2022) membandingkan metode *Machine Learning* (ML) dan *Deep learning* (DL) untuk klasifikasi kanker kulit menggunakan *dataset* Kaggle (3.297 gambar) dan HAM10000 (>10.000 gambar). Algoritma ML yang digunakan meliputi Logistic Regression, k-NN, dan Decision Tree, sedangkan model DL mencakup CNN kustom dan *transfer learning* dengan VGG16, ResNet50, dan Xception. Hasilnya, VGG16 menunjukkan performa terbaik pada *dataset* HAM10000 dengan akurasi 88%, *precision* 68%, *recall* 71%, dan *f1-score* 70%. *Ensemble learning* meningkatkan *precision* hingga 79%.

Penelitian Agustina et al. (2022) menerapkan CNN arsitektur VGG-16 untuk klasifikasi kanker kulit

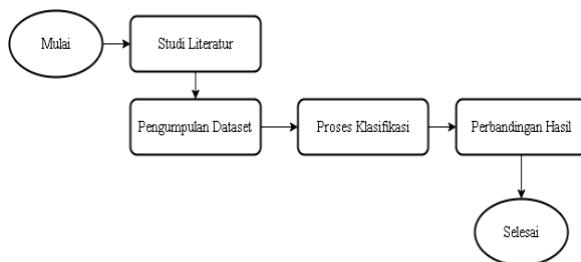
pada *dataset* 4.000 citra dengan 4 kelas. Penelitian dilakukan dalam berbagai tahapan yaitu *input* citra, *preprocessing*, pelatihan model dan pengujian sistem. Tahapan *preprocessing* mencakup proses *resizing* yang dilakukan dengan 2 teknik berbeda dan menjadi skenario pengujian yaitu penggunaan teknik CLAHE dan teknik Gaussian Filter. Hasil terbaik diperoleh tanpa *preprocessing* tambahan, menggunakan *optimizer* SGD, *learning rate* 0,001, epoch 50, dan batch size 32, dengan akurasi 99,70%, *loss* 0,0055, *precision* 99,75%, *recall* 99,75%, dan *f1-score* 99,50%.

Penelitian Saputra et al. (2023) membandingkan performa ResNet-152 dan AlexNet untuk klasifikasi kanker kulit pada *dataset* ISIC 2019, yang dikategorikan menjadi *benign* dan *malignant*. Penelitian menggunakan *optimizer* Adam dan Mini-Batch Gradient Descent (MBGD), hasil terbaik diperoleh arsitektur ResNet-152 dengan mencapai akurasi 87,85%, *precision* 87,25%, *recall* 88,65%, dan *f1-score* 87,95%.

Penelitian Sephya et al. (2024) membandingkan arsitektur VGG16 dan DenseNet121 untuk klasifikasi kanker kulit pada *dataset* ISIC berjumlah 2.357 citra dengan 9 kelas. Setelah *preprocessing* dan *data splitting* dengan rasio 80% data latih dan 20% data uji, model diuji menggunakan *confusion matrix*. Hasil menunjukkan bahwa DenseNet121 memiliki performa lebih baik dengan *train accuracy* 93% dan *testing accuracy* 79%, dibandingkan VGG16 yang mencapai *train accuracy* 80% dan *testing accuracy* 74%.

METODE PENELITIAN

Penelitian ini merupakan penelitian yang menggunakan pendekatan kuantitatif eksperimental, melakukan eksperimen menggunakan berbagai arsitektur *transfer learning* CNN untuk klasifikasi kanker kulit, di mana hasilnya berupa angka-angka dan akan dikumpulkan serta dianalisis berdasarkan pengukuran numerik. Langkah-langkah penelitian ditunjukkan pada gambar 1.



Gambar 1. Langkah-langkah penelitian

Studi Literature

Penelitian ini diawali dengan studi literatur mengenai teknik dan model DL untuk klasifikasi kanker kulit, termasuk arsitektur MobileNetV2, EfficientNetB0, dan DenseNet121. Kajian mencakup *transfer learning*, *fine-tuning*, serta teknik penyeimbang data seperti SMOTE untuk mengatasi distribusi kelas yang tidak seimbang. Sumber referensi diperoleh dari Google Scholar dan ScienceDirect, dengan fokus pada publikasi lima tahun terakhir untuk memastikan relevansi metode yang digunakan.

Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini adalah *dataset* dari Kaggle yang terdiri atas 2.357 citra kanker kulit dengan 9 kelas yaitu Actinic keratosis, Basal cell carcinoma, Benign keratosis, Dermatofibroma, Melanoma, Nevus, Squamous cell carcinoma, Seborrheic keratosis, dan Vascular lesion. Tabel 1 menyajikan distribusi data tiap kelas yang menunjukkan adanya ketidakseimbangan data pada tiap kelasnya.

Tabel 1. Distribusi data tiap kelas

Kelas	Jumlah Data
Pigmented benign keratosis	478
Melanoma	454
Vascular lesion	142
Actinic keratosis	130
Squamous cell carcinoma	197
Basal cell carcinoma	392
Seborrheic keratosis	80
Dermatofibroma	111
Nevus	373
Total	2.357

Sampel citra untuk tiap kelas ditunjukkan pada gambar 2. *Dataset* melalui proses *cleaning* sebelum digunakan dalam pelatihan model supaya bersih dari data duplikat. *Dataset* terdiri atas gambar-gambar dengan ukuran yang bervariasi sehingga dilakukan proses *resizing* untuk menyeragamkannya.



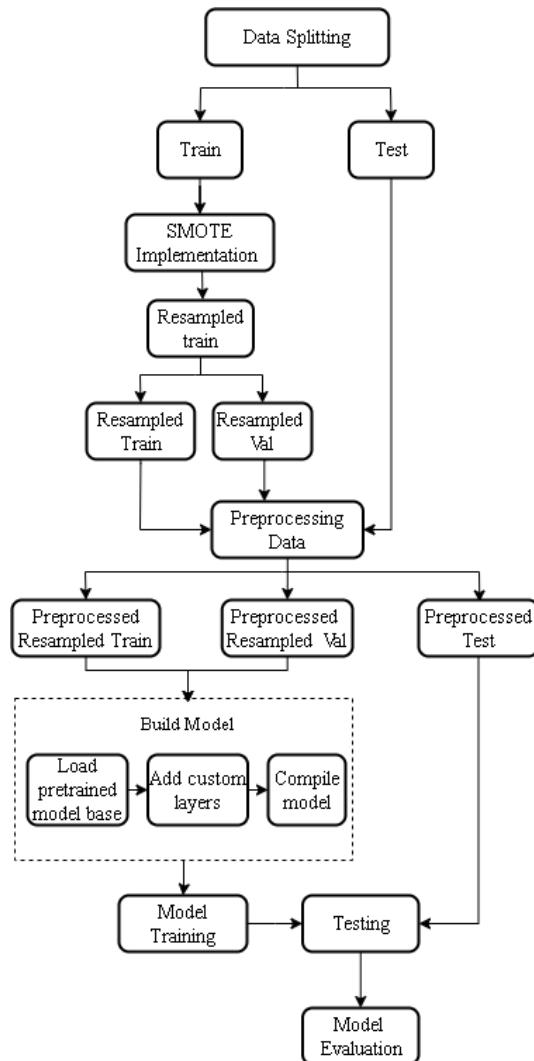
Gambar 2. Citra kanker kulit

Proses Klasifikasi

Tahapan-tahapan dalam proses klasifikasi ditunjukkan pada gambar 3, yaitu dimulai dengan *data splitting*, penerapan SMOTE, *preprocessing* data, *build* dan *training* model, *testing* model, dan evaluasi model. *Data splitting* dilakukan untuk membagi *dataset* menjadi 3 *subset* yaitu *training*, *validation* dan *testing*. Setelah *splitting* data, kemudian diterapkan SMOTE untuk *balancing* data dan dilakukan augmentasi data untuk meningkatkan variasi gambar.

Pembuatan model dimulai dengan memuat *base model* dan menambahkan *layer-layer* tambahan, kemudian model di *compile* untuk selanjutnya dilakukan pelatihan. Proses pelatihan model dilakukan dalam 50 epoch dengan menerapkan *callback* berupa ReduceLROnPlateau yang akan menyesuaikan nilai *learning rate* jika terjadi stagnasi dalam proses pelatihan. *Optimizer* yang digunakan adalah optimizer SGD dengan *learning rate* 0,001. *Function loss* yang digunakan adalah Categorical Focal Loss yang dipilih karena Focal loss mampu menangani ketidakseimbangan kelas dengan memberikan bobot yang lebih besar pada data yang sulit diklasifikasikan, sehingga model dapat belajar lebih baik pada kelas minoritas (Fajri, 2024).

Setelah pelatihan, model kemudian dievaluasi dengan menggunakan confusion matrix yang menghasilkan metrik evaluasi *accuracy*, *precision*, *recall*, dan *f1-score*. Pada penelitian ini juga dilakukan evaluasi model dengan metrik evaluasi Matthews Corellation Coefficient (MCC).



Gambar 3. Proses klasifikasi

Perbandingan Hasil

Skenario pengujian dalam penelitian ini yaitu terkait dengan penggunaan teknik SMOTE untuk balancing *dataset*. Pada tahap perbandingan hasil ini, akan dibandingkan hasil performa ketiga arsitektur yaitu DenseNet121, EfficientNetB0, dan MobileNetV2 sebelum dan sesudah penerapan SMOTE berdasarkan nilai metrik evaluasi yang didapatkan.

HASIL DAN PEMBAHASAN

Pengumpulan dan Pengolahan Data

Penelitian ini menggunakan *dataset* kanker kulit dengan 9 kelas berjumlah 2.357 citra dari Kaggle yaitu dari akun Andrey Katanskiy. Setelah proses cleaning ditemukan sebanyak 141 data duplikat, dan *dataset* berkurang menjadi 2.216 citra. *Dataset* yang awalnya terbagi dalam folder *train* dan *test* digabungkan ke dalam satu *dataframe* dengan kolom *image_path* dan *label*, lalu dilakukan *splitting* ulang. Label dalam format teks dikonversi ke numerik menggunakan

label_map. Gambar pada *dataset* dengan ukuran bervariasi di-*resize* menjadi 100x75 untuk mempertahankan rasio aspek dan efisiensi komputasi (Bagus Nurhannudin, 2024).

Preprocessing dan Penyelesaian Imbalanced Dataset

Dataset dibagi menjadi tiga subset (70% *training*, 15% *validation*, 15% *testing*) menggunakan *stratified splitting* untuk menjaga keseimbangan distribusi kelas. Teknik SMOTE diterapkan untuk menyeimbangkan kelas dengan menghasilkan data sintetis, dilakukan setelah memisahkan data *test* dari

data *training*. Augmentasi data dilakukan pada data hasil SMOTE untuk menambah variasi gambar dengan menggunakan teknik seperti *rotation range*, *width shift*, *height shift*, *horizontal flip*, *zoom range*, dan *fill mode*. Proses augmentasi dilakukan dengan *ImageDataGenerator()* dan hasilnya ditambahkan ke *dataset training*. *Dataset* kemudian diacak ulang, dinormalisasi menggunakan *mean* dan *std*, serta dikonversi ke format *one-hot encoding*. Semua data *reshape* agar sesuai untuk pemrosesan dalam model *deep learning*. Tabel 2 memperlihatkan hasil *splitting* data sebelum dan sesudah diterapkannya teknik SMOTE.

Tabel 2. Distribusi data setelah *splitting*

Kelas	Sebelum SMOTE			Setelah SMOTE		
	Train	Val	Test	Train	Val	Test
Actinic keratosis	91	20	19	669	143	19
Basal cell carcinoma	274	59	59	669	143	59
Dermatofibroma	77	17	17	669	143	17
Melanoma	264	56	57	669	143	57
Nevus	217	46	46	669	143	46
Pigmented benign keratosis	334	72	72	669	143	72
Seborrheic keratosis	56	12	12	669	143	12
Squamous cell carcinoma	138	29	30	669	143	30
Vascular Lesion	100	21	21	669	143	21

Build dan Training Model

Setelah tahap *preprocessing*, penelitian ini membangun dan melatih model menggunakan tiga arsitektur CNN yaitu DenseNet121, EfficientNetB0, dan MobileNetV2 dengan teknik *transfer learning* menggunakan bobot dari Imagenet. Setiap model dimodifikasi dengan lapisan tambahan seperti GlobalAveragePooling2D, Dropout, BatchNormalization, dan Fully Connected (Dense). Semua model menggunakan categorical focal loss dengan parameter gamma=1.5 dan alpha=0.5 untuk menangani ketidakseimbangan kelas dan SGD *optimizer* untuk meningkatkan generalisasi serta menghindari *local minima* yang buruk. Model dilatih selama 50 epoch dengan ReduceLROnPlateau untuk menyesuaikan *learning rate* saat pelatihan.

Hasil Pelatihan dan Pengujian Model

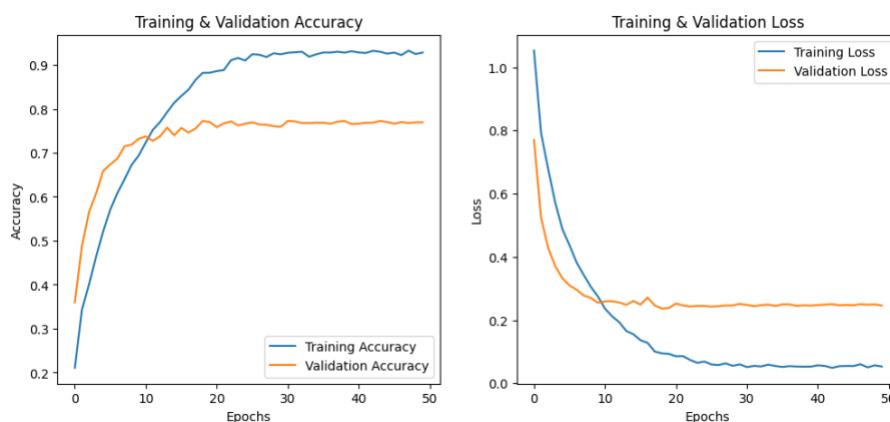
Penerapan SMOTE, performa model menunjukkan perbedaan yang cukup signifikan dalam keseimbangan antara *training*, *validation*, dan *test accuracy* seperti yang ditampilkan pada Tabel 3. DenseNet121 memiliki keseimbangan yang relatif baik dibandingkan model lain, dengan *training accuracy* sebesar 77,89%, *validation accuracy* sebesar 60,84%, dan *test accuracy* sebesar 64,56%. Akan tetapi, selisih antara *training accuracy* dan *validation accuracy* menunjukkan adanya *overfitting* yang perlu diperhatikan.

Tabel 3. Perbandingan Hasil *Training* dan *Testing* Sebelum SMOTE

Model	Metrik Evaluasi					
	Train Acc	Train Loss	Val Acc	Val Loss	Test Acc	Test loss
DenseNet121	0.7789	0.2110	0.6084	0.4260	0.6456	0.3776
EfficientNetB0	0.5854	0.4262	0.6355	0.4024	0.6186	0.4162
MobileNetV2	0.8704	0.1068	0.6867	0.3639	0.6306	0.4273

Tabel 4. Perbandingan Hasil *Training* dan *Testing* Setelah SMOTE

Model	Metrik Evaluasi					
	Train Acc	Train Loss	Val Acc	Val Loss	Test Acc	Test loss
DenseNet121 + SMOTE	0.9281	0.0532	0.7692	0.2463	0.6697	0.3824
EfficientNetB0 + SMOTE	0.6150	0.3563	0.6706	0.2948	0.6096	0.3390
MobileNetV2 + SMOTE	0.8816	0.0948	0.7195	0.2815	0.6264	0.4771



Gambar 4. Training dan Validation Accuracy dan Loss

Sementara itu, MobileNetV2 memiliki *training accuracy* tertinggi sebesar 87,04%, namun mengalami *overfitting* dengan selisih yang cukup besar yaitu *validation accuracy* (68,67%) dan *test accuracy* yang lebih rendah (63,06%). *Test loss* yang tinggi (0.4273) juga menunjukkan bahwa model ini mengalami kesulitan dalam melakukan generalisasi. Overfitting ini kemungkinan disebabkan oleh arsitektur MobileNetV2 yang relatif ringan dan cepat belajar, namun kurang mampu menggeneralisasi pada dataset kompleks dengan variasi tinggi seperti kanker kulit.

Berbeda dengan dua model sebelumnya, EfficientNetB0 menunjukkan performa yang lebih stabil dibandingkan MobileNetV2, dengan *training accuracy* sebesar 58,54%, *validation accuracy* sebesar 63,55%, dan *test accuracy* sebesar 61,86%. Meskipun akurasi pelatiannya lebih rendah dibandingkan model lain, model ini memiliki selisih yang lebih kecil antara *train*, *validation*, dan *test accuracy*, menunjukkan tingkat *overfitting* yang lebih rendah.

Setelah menerapkan SMOTE seperti yang ditunjukkan pada Tabel 4, terjadi peningkatan dalam keseimbangan klasifikasi, meskipun dengan variasi efektivitas pada masing-masing model. DenseNet121 mengalami peningkatan *training accuracy* dari 77,89% menjadi 92,81%, dan *validation accuracy* dari 60,84% menjadi 76,92%, sementara *test accuracy* juga meningkat sedikit menjadi 66,97%. *Train loss* yang

lebih rendah (0.0532) dibandingkan dengan *validation loss* (0.2463) menunjukkan bahwa model masih mengalami *overfitting*, tetapi tidak seberat sebelumnya.

Pada MobileNetV2, penerapan SMOTE meningkatkan *validation accuracy* dari 68,67% menjadi 71,95%, tetapi *test accuracy* justru sedikit menurun dari 63,06% menjadi 62,64%, dengan *test loss* yang meningkat signifikan menjadi 0.4771, yang menunjukkan ketidakstabilan dalam generalisasi model.

EfficientNetB0 meskipun memiliki *training accuracy* yang lebih rendah dibandingkan model lainnya, menunjukkan peningkatan *validation accuracy* dari 63,55% menjadi 67,06%, yang mengindikasikan model menjadi lebih generalisasi setelah penerapan SMOTE. Selain itu, *test loss* juga menurun dari 0.4162 menjadi 0.3390, menunjukkan bahwa model lebih stabil setelah oversampling dilakukan.

Dari hasil perbandingan dapat disimpulkan bahwa penerapan SMOTE memberikan dampak positif terhadap keseimbangan data dan meningkatkan performa model, terutama pada DenseNet121, yang tetap menjadi model terbaik setelah SMOTE diterapkan. Namun, efeknya bervariasi pada tiap modelnya, MobileNetV2 mengalami ketidakstabilan dalam generalisasi dan EfficientNetB0 menunjukkan peningkatan dalam generalisasi, meskipun dengan

akurasi yang lebih rendah. Gambar 4 menunjukkan grafik *accuracy* dan *loss* dari *training* dan *validation*.

Hasil Evaluasi Model

Tabel 5. Perbandingan evaluasi model sebelum SMOTE

Model	Metrik Evaluasi			
	Prec	Recall	F1-score	MCC
DenseNet121	0.65	0.65	0.64	0.5833
EfficientNetB0	0.62	0.62	0.60	0.5501
MobileNetV2	0.65	0.63	0.63	0.5688

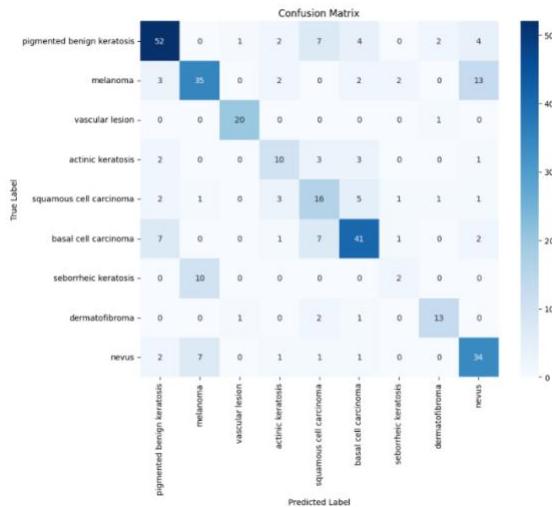
Berdasarkan hasil evaluasi metrik tanpa penerapan SMOTE, DenseNet121 menunjukkan performa terbaik dengan *precision* 0.65, *recall* 0.65, *F1-score* 0.64, dan MCC tertinggi sebesar 0.5833. MobileNetV2 memiliki *precision* yang sama (0.65) tetapi *recall* lebih rendah (0.63), menghasilkan *F1-score* 0.63 dan MCC 0.5688. EfficientNetB0 memiliki metrik evaluasi terendah dengan *precision* dan *recall* sebesar 0.62, *F1-score* 0.60, serta MCC 0.5501. DenseNet121 tetap menjadi model terbaik dalam keseimbangan performa tanpa SMOTE.

Tabel 6. Perbandingan evaluasi model setelah SMOTE

Model	Metrik Evaluasi			
	Prec	Recall	F1-score	MCC
DenseNet121 + SMOTE	0.67	0.67	0.67	0.6143
EfficientNetB0 + SMOTE	0.65	0.61	0.62	0.5535
MobileNetV2 + SMOTE	0.62	0.62	0.62	0.5606

Setelah penerapan SMOTE, DenseNet121 + SMOTE menunjukkan performa terbaik dengan *training accuracy* 92,81%, *validation accuracy* 76,92%, dan *test accuracy* 66,97%. Model ini memiliki MCC tertinggi (0.6143) dan keseimbangan yang lebih baik dalam *precision*, *recall*, serta *F1-score*. Meskipun masih mengalami sedikit *overfitting*, perbedaannya lebih kecil dibanding sebelum SMOTE diterapkan. EfficientNetB0 + SMOTE menunjukkan peningkatan generalisasi dengan *validation accuracy* lebih tinggi (67,06%) dibanding sebelumnya, tetapi performanya tetap lebih rendah dari DenseNet121 + SMOTE. MobileNetV2 + SMOTE mengalami ketidakstabilan

dengan peningkatan *test loss*, meskipun *recall* untuk beberapa kelas meningkat.



Gambar 5. Confusion Matrix DenseNet121 + SMOTE

Gambar 5 menunjukkan confusion matrix model DenseNet121+SMOTE, dimana unggul dalam klasifikasi Vascular Lesion (*F1-score* 0.93) dan Pigmented Benign Keratosis (*F1-score* 0.74), tetapi kurang optimal dalam Seborrheic Keratosis (*F1-score* 0.33). Arsitektur DenseNet121 dengan ciri khas *dense connections* memungkinkan pemanfaatan fitur secara maksimal dan meningkatkan aliran gradien selama penelitian sehingga mengurangi *vanishing gradient* dan hasilnya lebih stabil.

Secara keseluruhan, DenseNet121 + SMOTE menjadi model terbaik setelah penerapan SMOTE dengan keseimbangan performa yang lebih baik dibandingkan model lainnya. Hasil ini sejalan dengan penelitian Septhya et al. (2024) yang membandingkan arsitekur VGG16 dengan DenseNet121 dalam klasifikasi kanker kulit, dimana didapatkan pula model DenseNet121 merupakan model dengan hasil terbaik.

KESIMPULAN

Sebelum penerapan SMOTE, model terbaik adalah DenseNet121 dengan *test accuracy* 64,56%. Model ini memiliki keseimbangan terbaik dalam *precision*, *recall*, dan *F1-score* dibandingkan MobileNetV2 dan EfficientNetB0. MobileNetV2 memiliki *train accuracy* tertinggi tetapi mengalami *overfitting*, sementara EfficientNetB0 lebih stabil namun memiliki *test accuracy* lebih rendah. Ketidakseimbangan data menyebabkan kelas minoritas sulit diklasifikasikan dengan baik, terlihat dari *F1-score* yang rendah pada beberapa kelas.

Setelah menerapkan SMOTE, DenseNet121 tetap unggul dengan *test accuracy* meningkat menjadi 66.97% dan MCC tertinggi sebesar 0.6143. Teknik SMOTE membantu meningkatkan *recall* kelas minoritas, meskipun tidak semua kelas mengalami peningkatan signifikan. EfficientNetB0 menjadi lebih stabil, sementara MobileNetV2 mengalami ketidakstabilan, dengan *test loss* yang lebih tinggi setelah SMOTE diterapkan. SMOTE membantu meningkatkan *recall* dan MCC, terutama untuk kelas minoritas, tetapi tidak selalu meningkatkan *test accuracy* dan dapat menyebabkan ketidakstabilan pada beberapa model.

Penelitian ini hanya berfokus pada tiga arsitektur CNN yaitu DenseNet121, EfficientNetB0, dan MobileNetV2. Dataset yang digunakan pada penelitian ini memiliki distribusi kelas tidak seimbang dan jumlah sampel terbatas yang berpengaruh terhadap hasil evaluasi model. Meskipun penerapan SMOTE memberikan dampak positif dengan meningkatkan performa model, namun tidak menutup kemungkinan bahwa terdapat teknik lain yang dapat menangani ketidakseimbangan data dengan lebih baik. Oleh karena itu, perlu eksplorasi lebih lanjut untuk pendekatan lain dalam penanganan ketidakseimbangan untuk klasifikasi kanker kulit. Penelitian selanjutnya juga dapat memperluas cakupan dengan mempertimbangkan arsitektur model lain dan dataset yang lebih besar dan bervariasi supaya generalisasi model lebih baik.

DAFTAR PUSTAKA

- Agustina, R., Magdalena, R., & Pratiwi, N. K. C. (2022). Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(2), 446. <https://doi.org/10.26760/elkomika.v10i2.446>
- Ali, K., Shaikh, Z. A., Khan, A. A., & Laghari, A. A. (2022). Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer. *Neuroscience Informatics*, 2(4), 100034. <https://doi.org/10.1016/j.neuri.2021.100034>
- Awalia, N., & Primajaya, A. (2022). Identifikasi Penyakit Leaf Mold Daun Tomat Menggunakan Model DenseNet121 Berbasis Transfer Learning. *Jurnal Ilmiah Komputer*, 8(1), 49–54. <http://ejournal.fikom-unasman.ac.id>
- Bagus Nurhannudin. (2024). Perancangan Sistem Deteksi Tingkat Kemiringan Jalan Sederhana Dengan Metode Otsu Thresholding Menggunakan Colab. *Router : Jurnal Teknik Informatika Dan Terapan*, 2(3), 137–146. <https://doi.org/10.62951/router.v2i3.156>
- Bechelli, S., & Delhommelle, J. (2022). Machine Learning and Deep Learning Algorithms for Skin Cancer Classification from Dermoscopic Images. *Bioengineering*, 9(3). <https://doi.org/10.3390/bioengineering9030097>
- Dartiko, F., Pradana, R. J., Sari, R. E., Syahputra, W., & Oktoeberza, W. K. (2024). Klasifikasi Kanker Kulit Berbasis CNN dengan Metode Hybrid Preprocessing. *Medika Teknika : Jurnal Teknik Elektromedik Indonesia*, 5(2), 124–132. <https://doi.org/10.18196/mt.v5i2.22675>
- Duman, E., & Tolan, Z. (2021). Comparing Popular CNN Models for an Imbalanced Dataset of Dermoscopic Images. *Computer Science*. <https://doi.org/10.53070/bbd.990574>
- Fajri, F. P. Al. (2024). Perancangan Model Deep Learning untuk Penerjemah Bahasa Isyarat SIBI menggunakan Transfer Learning MobileNetV2. Sekolah Tinggi Teknologi Terpadu Nurul Fikri.
- Harahap, F. A. A., Nafisa, A. N., Purba, E. N. D. B., & Putri, N. A. (2023). Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor otak Glioma, Pituitary dan Meningioma. *Jurnal Teknologi Informasi, Komputer, Dan Aplikasinya (JTIKA)*, 5(1), 53–61. <https://doi.org/10.29303/jtika.v5i1.234>
- Indraswari, R., Herulambang, W., & Rokhana, R. (2022). Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (CNN). *Techno. Com*, 21(2).
- Kurniawan, W. A., & Salam, A. (2024). Penggunaan Feature Space SMOTE Untuk Mengurangi Overfitting Akibat Imbalance Dataset. *Techno. Com*, 23(2), 328–337. <https://doi.org/10.62411/tc.v23i2.10215>
- Rahman, Z., & Ami, A. M. (2020). A transfer learning based approach for skin lesion classification from imbalanced data. *Proceedings of 2020 11th International Conference on Electrical and Computer Engineering, ICECE 2020*, 65–68. <https://doi.org/10.1109/ICECE51571.2020.9393155>
- Ramdhana, A. C., & Pratiwi, N. (2023). Perbandingan Kinerja Model Convolutional Neural Network pada Klasifikasi Kanker Kulit. *Edumatic: Jurnal Pendidikan Informatika*, 7(2), 197–206. <https://doi.org/10.29408/edumatic.v7i2.19823>
- Saputra, T., Ezar, M., & Rivan, A. (2023). Analisis Performa ResNet-152 dan AlexNet dalam Klasifikasi Jenis Kanker Kulit. *STRING (Satuan Tulisan Riset Dan Inovasi Teknologi)*, 8(1), 75–84. <https://challenge.isic.org/>
- Saputro, R. R., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi Penyakit Kanker Kulit Menggunakan Metode Convolutional Neural Network (Studi

- Kasus: Melanoma). *Data Institut Teknologi Telkom Purwokerto*, 2(1), 52–57.
- Septhya, D., Rahmaddeni, Susanti, & Agustin. (2024). Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Penyakit Kanker Kulit. *The Indonesian Journal of Computer Science*, 13(4), 6590–6600.
<https://doi.org/10.33022/ijcs.v13i4.4262>
- Subagio, M. M., Bhakti, M. S., Yulestiono, A. Y., & Sari, A. P. (2024). Perbandingan Kinerja Metode Convolutional Neural Network (CNN) dan VGG-16 dalam Klasifikasi Rambu Lalu Lintas. *Jurnal Mahasiswa Teknik Informatika*, 3(2), 79–87.
<https://doi.org/10.35473/jamastika.v3i2.3361>
- Sundari, N. A., Magdalena, R., & Saidah, S. (2022). Klasifikasi Jenis Kulit Wajah Menggunakan Metode Convolutional Neural Network (CNN) Efficientnet-B0. *E-Proceeding of Engineering*, 8(6), 3180–3187.
- Wedayani, N., Putri R, N. A., & Hidajat, D. (2022). Edukasi Tentang Pengenalan Tanda Gejala, Pencegahan dan Penanganan Kanker Kulit Sebagai Dampak Paparan Sinar Matahari dan Penggunaan Kosmetik Berbahaya Kimia Berbahaya di Poli Kulit Rumah Sakit Akademik Universitas Mataram. *Jurnal Pengabdian Magister Pendidikan IPA*, 5(3), 223–226.
<https://doi.org/10.29303/jpmipi.v5i3.2133>
- World Health Organization. (2022, February 3). *Cancer*. <https://www.who.int/news-room/fact-sheets/detail/cancer>