

## Perbandingan Kinerja Model Convolutional Neural Network pada Klasifikasi Kanker Kulit

Arlingga Cahya Ramdhana<sup>1</sup>, Nunik Pratiwi<sup>1,\*</sup>

<sup>1</sup> Program Studi Teknik Informatika, Universitas Muhammadiyah Prof. Dr. Hamka, Indonesia

\* Correspondence: npratiwi@uhamka.ac.id

**Copyright:** © 2023 by the authors

Received: 6 Juli 2023 | Revised: 9 Juli 2023 | Accepted: 19 Agustus 2023 | Published: 20 Juli 2023

### Abstrak

Kanker kulit merupakan salah satu penyakit yang sangat mempengaruhi kualitas hidup manusia dan dapat berpotensi buruk jika tidak terdeteksi dan ditangani dengan cepat. Dalam upaya untuk meningkatkan deteksi dini dan akurasi diagnosis kanker kulit, penelitian ini bertujuan untuk merancang sistem klasifikasi kanker kulit menggunakan deep learning. Metode penelitian ini melibatkan penggunaan jaringan saraf tiruan berbasis deep learning, terutama *convolutional neural network* (CNN), yang telah terbukti efektif dalam pengolahan citra. Citra pada dataset tersebut mencakup berbagai jenis kanker kulit, termasuk melanoma dan karsinoma sel basal. Pada penelitian ini, sistem klasifikasi kanker kulit dibangun dengan menggunakan The-HAM10000 Dataverse, dengan memanfaatkan algoritma CNN dan performa dari sistem yang dibuat menggunakan model InceptionV3, dan EfficientNetB0. Hasil dari kedua metode ini pada dataset tersebut menghasilkan bahwa InceptionV3 memiliki akurasi sebesar 0.7681, dan EfficientNetB0 sebesar 0.9809, hasil dari akurasi tersebut menjadikan sistem EfficientNetB0 lebih baik untuk deteksi kanker kulit, sehingga temuan ini menjadikan bahwa akurasi di tingkat demikian akan mengklasifikasi sebanyak 327 data saja, maka dari itu data yang dilatih dan diuji akan menghasilkan sebuah akurasi dan *error* dari validasinya yang menjadikan EfficientNetB0 sebuah pilihan untuk dilakukannya klasifikasi berdasarkan metode CNN.

**Kata kunci:** kanker kulit; deteksi dini; algoritma cnn; model inceptionv3; model efficientnetb0

### Abstract

*Skin cancer is one of the diseases that greatly affects the quality of human life and can be potentially bad if not detected and treated quickly. In an effort to improve the early detection and accuracy of skin cancer diagnosis, this study aims to design a skin cancer classification system using deep learning. The research method involves the use of deep learning-based artificial neural networks, especially convolutional neural networks (CNN), which have been proven effective in image processing. The images in the dataset include various types of skin cancer, including melanoma and basal cell carcinoma. In this study, a skin cancer classification system was built using The-HAM10000 Dataverse, utilizing the CNN algorithm and the performance of the system was modeled using InceptionV3, and EfficientNetB0. The results of these two methods on the dataset show that InceptionV3 has an accuracy of 0.7681, and EfficientNetB0 of 0.9809, the results of this accuracy make the EfficientNetB0 system better for skin cancer detection, so this finding makes that the accuracy at this level will classify as much as 327 data only, therefore the data trained and tested will produce an accuracy and error from its validation which makes EfficientNetB0 an option for classification based on the CNN method.*

**Keywords:** skin cancer; early detection; cnn algorithm; inceptionv3model; efficientnetb0 model

## PENDAHULUAN

Kanker kulit merupakan salah satu kanker ganas yang paling banyak terjadi di Indonesia dan berakibat fatal menyesuaikan dengan yang diderita oleh pasien. Seorang dokter kulit



mendiagnosa kanker kulit secara manual menggunakan biopsi dan mikroskop, namun proses ini memakan waktu lama dan membawa resiko kecelakaan selama proses biopsi (Yohannes & Al Rivan, 2022). Indonesia juga merupakan negara khatulistiwa, sehingga matahari langsung memaparkan sinarnya kepada penjuru Indonesia, dan membuat radiasi matahari langsung masuk ke bumi sebanyak 93-99% meskipun diserap oleh lapisan ozon, perkembangan zaman tidak bisa menipu matahari, maka dari itu sinar *ultraviolet* masuk ke bumi khususnya Indonesia yang dilewati khatulistiwa dan dapat menyebabkan berbagai macam penyakit kanker kulit (Nurlitasari et al., 2022), begitu juga dengan penelitian lainnya yang menyatakan bahwa Indonesia dengan iklim tropis yang mana matahari langsung menyengat ke kulit manusia, sehingga akan ada perusakan pada bagian lapisan atas kulit, karena terlalu sering terpapar sinar ultraviolet, akibatnya data menunjukkan 50% sampai 90% permasalahan yang ada di kulit dikarenakan sinar ultraviolet atau radiasi sinar matahari (Haq, 2020). Dari permasalahan yang telah dijabarkan didapat banyak pihak medis yang memerlukan kecepatan dan efisiensi waktu yang signifikan (Duman & Tolan, 2021), maka dari itu penelitian ini dilakukan untuk mengambil performansi dari kedua model arsitektur dari *Convolutional Neural Network* (CNN) yaitu InceptionV3 dan juga EfficientNetB0, dengan itu dapat dipilih dan dilakukan uji akurasi dari kedua model tersebut, dan diambil akurasi serta efisiensi terbaik dari keduanya.

Pendekatan yang mengadopsi CNN dalam analisis citra untuk deteksi dini dan klasifikasi (Nurkhasanah & Murinto, 2022; Sitompul et al., 2022) kanker kulit didukung oleh kemampuan hierarkis mempelajari fitur dari data citra melalui lapisan-lapisan konvolusi dan *pooling*, memungkinkan pengenalan pola visual kompleks seperti tekstur dan bentuk kanker. Keunggulan CNN dalam mendeteksi fitur yang invariant terhadap variasi posisi dan ukuran citra serta kemampuan fokus pada bagian-bagian kecil citra mirip dengan pemrosesan visual manusia. Selain itu, teknik transfer learning juga memperkuat kinerja CNN dalam tugas deteksi kanker kulit dengan memanfaatkan pengetahuan yang telah dipelajari dari dataset citra besar sebelumnya.

Satu aspek yang menjadi pijakan teori pendukung adalah perlunya perbandingan yang lebih komprehensif dengan metode lain. Meskipun penelitian sebelumnya, seperti yang dilakukan oleh Nurlitasari et al. (2022), mencapai akurasi yang luar biasa melalui penggunaan CNN, perbandingan tersebut sering kali terbatas pada analisis internal CNN tanpa perbandingan yang mendalam dengan metode lain. Dengan mempertimbangkan berbagai metode, dapat diidentifikasi kelebihan dan kekurangan masing-masing pendekatan, memberikan wawasan lebih dalam tentang keefektifan relatif dan pilihan terbaik untuk klasifikasi kanker kulit.

Selain itu, penting untuk mencatat bahwa pemilihan dataset yang representatif adalah faktor penentu dalam keberhasilan model klasifikasi. Dataset yang luas dan mencakup berbagai jenis kanker kulit akan memberikan informasi yang lebih baik kepada model tentang variasi kondisi kulit. Studi yang lebih mendalam, seperti penelitian oleh (Saputro et al., 2022), menunjukkan bahwa ukuran dataset yang terbatas dan fokus pada satu jenis kanker kulit, seperti melanoma, dapat menghasilkan pembatasan dalam generalisasi model. Oleh karena itu, penting untuk memilih dataset yang mencakup berbagai variasi kanker kulit, memastikan bahwa model memiliki pengetahuan yang cukup untuk mengenali dan mengklasifikasikan berbagai jenis kanker kulit. Dalam konteks ini, penelitian ini memiliki relevansi yang penting.

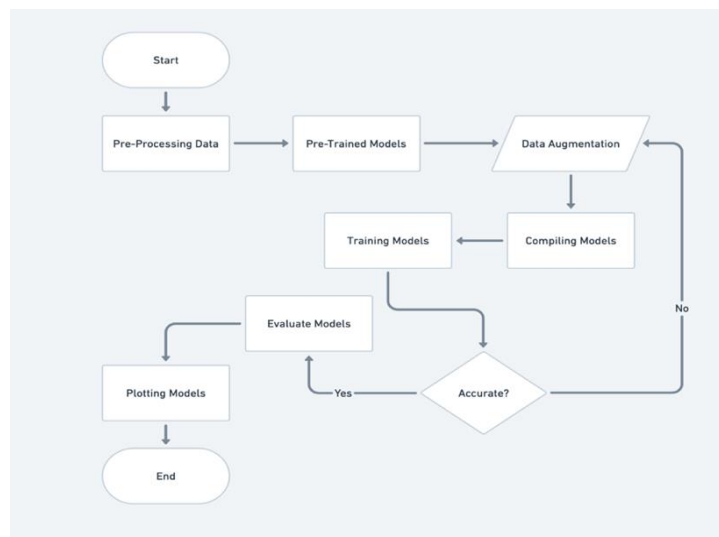
Berdasarkan penelitian sebelumnya yang masih memiliki kekurangan dalam kecepatan dan efisiensinya, penelitian ini bertujuan untuk mengembangkan perbandingan lebih mendalam antara metode CNN yang berbeda, seperti InceptionV3 dan EfficientNetB0, dalam pendeteksian kanker kulit, karena pada penelitian sebelumnya (Nurlitasari et al., 2022; Saputro et al., 2022) yang mana menggunakan metode CNN yang kaku dan tidak efisien alhasil penulis menggunakan metode CNN yang lebih modern. Perbandingan ini bukan hanya mengacu pada

akurasi, tetapi juga pada kemampuan generalisasi dan performa model di berbagai situasi. Keseluruhan tujuan ini sangat penting untuk memahami lebih lanjut potensi dan keterbatasan masing-masing arsitektur CNN.

Penting untuk diingat bahwa akurasi klasifikasi tidak hanya ditentukan oleh kekuatan komputasi dan arsitektur model semata. Sebaliknya, sifat inputan, dalam hal ini citra kulit, juga memainkan peran vital dalam hasil akhir. Oleh karena itu, penelitian ini berupaya untuk memberikan pandangan holistik tentang performa CNN dalam deteksi dan klasifikasi kanker kulit, membuka jalan bagi pengembangan sistem pengklasifikasian yang lebih akurat dan berkinerja tinggi di masa depan.

Secara keseluruhan, penelitian ini memiliki tujuan bahwa yang jelas dalam mengisi celah pengetahuan dan pemahaman sebelumnya. Dengan melakukan perbandingan antara metode CNN yang berbeda dalam konteks klasifikasi kanker kulit, penelitian ini berharap memberikan kontribusi berharga dalam mengembangkan alat-alat diagnostik yang lebih unggul dan akurat, yang pada akhirnya dapat meningkatkan perawatan dan deteksi dini kanker kulit.

## METODE



**Gambar 1.** *Convolutional neural network* alir diagram pengembangan sistem.

Tahapan untuk membuat sistem klasifikasi kanker kulit pada penelitian ini dimulai dengan data preprocessing. Proses ini melibatkan penyelesaian imbalanced data, di mana data yang tidak seimbang dihilangkan dan disama-ratakan untuk mencapai keseimbangan. Setelah itu, dilakukan optimasi terhadap model yang akan ditraining untuk meningkatkan performanya. Tahap terakhir adalah melakukan training models agar mendapatkan akurasi dan precision dari data yang sudah ditraining. Seluruh proses pengembangan sistem ini direpresentasikan dalam gambar 1.

CNN telah terbukti menjadi pilihan yang kuat dalam pemahaman citra medis. Para peneliti telah mengaplikasikan CNN dalam berbagai aplikasi pemahaman citra medis seperti deteksi tumor dan klasifikasinya menjadi jinak dan ganas (Montalbo & Alon, 2021), deteksi lesi kulit, citra tomografi koherensi optic (Sarvamangala & Kulkarni, 2022), dan sebagainya. Dalam penelitian ini, data akan diolah menggunakan metode deep learning dengan menggunakan algoritma CNN. Metode ini memiliki 13 lapisan, di mana 12 lapisan merupakan convolutional layers, dan 1 lapisan terkoneksi sebelum atau setelahnya (Agyenta & Akanzawon, 2022).

Lapisan-lapisan *convolutional* secara hirarkis mengidentifikasi fitur-fitur tingkat rendah hingga tingkat tinggi dari citra, seperti tepi, tekstur, objek, dan bentuk (Tian et al., 2021). Proses


konvolusi dalam CNN dapat dilihat dalam persamaan 1, di mana  $j$  adalah tensor input,  $\chi$  adalah konvolusi kernel, dan  $B$  adalah bias neural.

$$\Sigma O = (j * \chi) + B \tag{1}$$


Yang mana:

- $j$  : ialah tensor input
- $\chi$  : ialah konvolusi kernel
- $B$  : ialah bias *neural*

Proses pelatihan data menggunakan dataset The-HAM10000, yang berisi data citra kanker kulit. Data dilakukan rescaling menjadi 228x228 piksel dan dilakukan pengujian terhadap arsitektur InceptionV3 dan EfficientNetB0 (Tan & Le, 2019). Hasil penelitian ini akan menginformasikan akurasi dari masing-masing klasifikasi arsitektur yang digunakan. InceptionV3 merupakan model ketiga dari model inception pada CNN. Tujuannya adalah meningkatkan efisiensi dan mengurangi sumber daya komputasi, parameter, dan waktu training yang digunakan (Kim, 2022). Arsitektur InceptionV3 terdiri dari serangkaian convolution layer dengan filter berukuran 1x1, 5x5, dan 3x3, serta Maxpooling layer (Jignesh Chowdary et al., 2020), ditampilkan dalam gambar 2.



Gambar 2. Arsitektur inceptionv3



Gambar 3. Arsitektur efficientnetb0

EfficientNetB0 dipilih karena memiliki jumlah parameter minimum dan memberikan hasil yang menjanjikan. Model ini disesuaikan dengan dataset yang mengalami imbalanced data, dan jumlah data training diatasi dengan mengurangi data hingga 327. Arsitektur EfficientNetB0 ditampilkan dalam gambar 3.

Mengikuti tahapan data preprocessing, penyelesaian imbalanced data, optimasi model, dan training models menggunakan arsitektur InceptionV3 dan EfficientNetB0, penelitian ini bertujuan untuk menghasilkan sistem klasifikasi kanker kulit yang akurat dan efisien. Informasi dari hasil penelitian ini akan membantu dalam pengembangan sistem informasi lebih lanjut

yang menggunakan klasifikasi citra untuk deteksi dan diagnosis kanker kulit secara lebih efektif.

## HASIL DAN PEMBAHASAN


### Hasil

Dataset yang digunakan yaitu dataset dari *Harvard University*, yang mana dataset ini bernama *TheHAM-10000 Mnist Skin Cancer*. Dataset ini terdiri dari 10,015 *lesion\_id* (kunci data dari dataset), *image\_id* (kesinambungan antara data numerik dengan data citra), *dx* (kunci dari tipe kanker kulit), *dx\_type* (tipe dari kanker kulit), *sex* (jenis kelamin), *localization* (tempatny), *cell\_type* (nama dari jenis kanker kulitnya). Data *preprocessing* merupakan normalisasi data yang dibuat untuk meminimalisir data *noise*, yang nantinya akan berpengaruh ketika proses *training* data dan *validation* data. Deskripsi terkait dataset, serta frekuensi dari masing masing fitur dataset akan terlihat pada tabel 1. Hasil dari tabel ini menjadikan preprocessing dapat dilanjutkan secara lebih karena data pada tiap kolom sangat stabil.

**Tabel 1.** Deskripsi isi dataset

Nama	Tipe	Deskripsi	Frekuensi
lesion_id	object	Data unik dari tipe kanker kulit	10,015
image_id	object	Data unik dari citra kanker kulit	10,015
dx	int	Kunci dari tipe cell_type	10,015
dx_type	object	Jenis vonis kanker kulit	10,015
age	float	Umur penderita	10,015
sex	object	Jenis kelamin penderita	10,015
localization	string	Daerah kanker kulit	10,015
cell_type	string	Jenis kanker kulit	10,015

Pada The-HAM10000 dataset, secara frekuensi bernilai sama secara merata karena secara pengklasifikasiannya bisa dilakukan dari setiap kolom dari data set ini. Akan tetapi ketika melihat secara pembagiannya maka kita akan melihatnya dari *cell\_type* yang akan ditampilkan di gambar 4, dan divisualisasikan secara perataannya, dan dapat terlihat perbedaan yang jauh dari perbandingan data *nevi* dengan data yang lainnya. Pada gambar 4 ada imbalanced data yang mana melanocytic nevi sebanyak 5403 data, sehingga menjadikan data tertinggi dan ini akan menjadi data noise karena memiliki data terbanyak dan perlu adanya penyama-rataan dari frekuensi tiap jenis kanker kulitnya.




**Gambar 4.** Frekuensi data yang dilihat dari jenis kanker kulitnya

Selanjutnya pada gambar 5 terlihat hasil setelah preprocessing dan menghilangkan imbalanced data tersebut. Selanjutnya penelitian ini akan menggunakan data sebanyak 327 dari

masing masing tipe atau jenis kanker kulit. Sebelum itu ada 2 data terendah yaitu vascular lesions sebanyak 142 dan juga dermatofibroma sebanyak 115.

Pada gambar 5 didapati data *imbalanced* yang perlu dihilangkan karena data tersebut dapat membuat data noise juga karena ketika data terlalu sedikit maka akan menjadi *imbalanced* data juga sehingga penelitian ini akan memakai *actinic keratoses* dengan data sebanyak 327, penelitian ini akan menggunakan 327 data, dan sisa dari jenis kanker kulit lainnya akan disesuaikan dengan banyaknya data pada tipe *actinic keratoses* dan akan ditampilkan pada gambar 5 serta data setelah preprocessing akan ditampilkan pada tabel 2.



**Gambar 5.** Frekuensi data setelah *preprocessing* dan menghilangkan *imbalanced* data.

**Tabel 2.** Data 5 teratas setelah *preprocessing*

image_id	path	cell_type	cell_type_idx
ISIC_0026769	../data/HAM10000_images_part_1/ISIC_0026769.jpg	Benign keratosis-like lesions	2
ISIC_0025661	../data/HAM10000_images_part_1/ISIC_0025661.jpg	Benign keratosis-like lesions	2
ISIC_0029176	../data/HAM10000_images_part_1/ISIC_0029176.jpg	Benign keratosis-like lesions	2
ISIC_0025276	../data/HAM10000_images_part_1/ISIC_0025276.jpg	Benign keratosis-like lesions	2
ISIC_0025984	../data/HAM10000_images_part_1/ISIC_0025984.jpg	Benign keratosis-like lesions	2

Model yang akan di training nantinya akan di evaluasi dan melewati tahap *pre-trained models* sehingga diperlukan untuk melihat data *training* dan validasinya. Pada penelitian ini training dan validasi dari dataset dilakukan ketiga tahap yaitu pertama setelah membuat dataset menjadi *balanced*, sehingga bisa dilakukan *training models* dan juga dengan menggunakan utilisasi pada *module keras* dari *tensorflow* yaitu utilisasi *image\_dataset* dengan memberikan parameter sebagai validasi dan melihat berapa banyak data yang bisa ditraining dan validasi, maka akan memberikan data seperti pada tabel 3.

Pada tabel 3 memberikan informasi tentang distribusi kelas dan jumlah data yang digunakan dalam tahap pelatihan (*training*) dan validasi (*validation*) dalam suatu eksperimen atau pengolahan data. Terdapat total 5 kelas yang dianalisis dalam dataset tersebut. Untuk setiap kelas, terdapat 1635 data yang digunakan untuk pelatihan, serta 1145 data yang digunakan untuk validasi. Jumlah total data dalam tahap pelatihan adalah  $1145 * 5 = 8075$ , sedangkan untuk tahap validasi, terdapat 490 data.

Hal ini memberikan gambaran tentang bagaimana data terbagi dan digunakan dalam proses pelatihan dan evaluasi model, dengan memperhatikan variasi di antara berbagai kelas yang ada. Kelas yang akan ditraining ada sebanyak 5 kelas yang menyesuaikan dengan *cell\_type* pada tabel diatas kemudian, sebelum data *ditraining* dan validasinya, maka akan di *rescaling*, dengan skala  $1/255$ , sehingga ketika *training* data menjadi tidak berat, dan juga validasi yang diambil akan sama dengan data pada tabel 3, dan akhir dari *rescaling* ini akan membuat masing - masing inputan citra dinormalisasi dengan melihat *batch* dari citra, serta mengambil *pixel array* yang di set dengan *range* 0 sampai 1, sehingga dapat dilihat pada tabel 5, nilai minimal dan maksimal dari citra yang menjadi inputan, dan selain mengambil *range* 0 sampai 1 akan membentuk citra yang ada pada dataset berubah menjadi 228x228x3.

**Tabel 3.** Banyak kelas, dan data untuk *training* serta *validation*

	<i>classes</i>	<i>training</i>	<i>validation</i>
Banyak kelas	5	5	5
Banyak data	1635	1145	490

**Tabel 4.** Nilai minimal dan maksimal dari inputan citra pada dataset


<b>Minimal</b>	<b>Maksimal</b>
0,00055000786	0,79066163

Pada tabel 4 memperlihatkan rentang nilai minimal dan maksimal dari input citra yang ada dalam dataset. Nilai terendah yang ditemukan dalam dataset ini adalah sekitar 0,00055000786, sementara nilai tertingginya mencapai sekitar 0,79066163. Ini mengindikasikan bahwa dalam dataset tersebut, nilai piksel pada citra berkisar mulai dari nilai terendah yang sangat kecil hingga nilai tertinggi yang lebih besar, menciptakan variasi yang mencakup rentang yang cukup luas. Secara spesifik kami memberikan evaluasi dari model yang telah dibuat dengan menggabungkan InceptionV3 dan juga EfficientNetB0 secara parsial, dan juga memberikan nilai epoch yang sama yaitu di angka 10, serta pada saat training data dilakukan maka model dari data tersebut akan mempengaruhi nilai dari *loss* dan *accuracy* dari masing masing model CNN sehingga akan signifikan perbedaannya. Perbedaan dari rata - rata dari akurasi dan loss data pada kedua model CNN akan ditampilkan pada tabel 5.

**Tabel 5.** Perbandingan *loss* data dan *accuracy*

<i>Average data</i>	<i>InceptionV3</i>	<i>EfficientNetB0</i>
<i>loss</i>	0,7505	0,8055
<i>accuracy</i>	0,7681	0,9809

Pada perbedaan yang signifikan terlihat saat EfficientNetB0 menunjukkan kinerja yang lebih baik dalam memilih akurasi dan ini berkaitan dengan parameter yang telah diatur dengan baik dari model EfficientNetB0. Sebagai hasilnya, akurasi yang dihasilkan oleh EfficientNetB0 lebih unggul dibandingkan InceptionV3. Perbedaan ini dapat dilihat dari perbandingan kinerja keduanya saat menggunakan dataset yang telah di-preprocessing. EfficientNetB0 juga menghasilkan waktu inferens yang lebih cepat, yaitu 5,3 menit, dibandingkan InceptionV3 yang memerlukan 7,8 menit. Kecepatan ini membuat EfficientNetB0 menjadi lebih menarik untuk digunakan oleh para ahli medis di masa depan. Hasil akurasi ini akan digunakan untuk penelitian selanjutnya dan akan diusahakan untuk meminimalkan waktu inferens agar lebih efisien. Penelitian juga memastikan bahwa data kanker kulit yang diuji sesuai dengan hasil medis untuk memastikan indikasi kanker kulit atau hanya tanda-tanda biasa seperti tanda lahir atau bekas luka.



**Gambar 6.** Hasil dari eksperimen dengan training data EfficientNetB0 dan InceptionV3

Hasil akurasi ketika menggunakan EfficientNetB0 jauh lebih baik dan lebih stabil daripada InceptionV3 sehingga pengkhususan dari setiap model dan juga dataset perlu dipertimbangkan ketika ingin melakukan training data, dan juga kita harus melihat tingkat ketebalan dari layer yang diberikan dari masing – masing model CNN dan juga berat dari bobotnya, sehingga akan mempermudah komputasi penghitungan akurasinya, dan juga kembali kepada kedalaman *density* modelnya, karena ini sangat berpengaruh kepada tiap penghitungan akurasinya dan juga komponen seperti validasi data, dan juga loss dari dataset, maka dari itu perlu diperhatikan untuk tingkat konsistensi dari dataset yang akan di *training*.

### Pembahasan

Hasil penelitian menunjukkan bahwa dataset The-HAM10000 mengalami ketidakseimbangan data (*imbalanced data*), yang mengakibatkan kesulitan dalam melakukan pengujian. Oleh karena itu, peneliti melakukan proses balancing pada dataset yang akan diuji untuk mencapai keseimbangan data. Hasil dari pengujian menggunakan metode EfficientNetB0 dan InceptionV3 menunjukkan nilai akurasi yang diperoleh. Penelitian ini menunjukkan bahwa akurasi model dipengaruhi oleh dua faktor utama, yaitu proses balancing dataset dan proses rescaling data citra.

Proses *balancing* dataset menjadi krusial dalam meningkatkan kinerja model, dan hasil pengujian menunjukkan bahwa model EfficientNetB0 lebih unggul dalam data citra dengan ukuran 228x228 piksel. Selanjutnya, penelitian ini menyajikan hasil pengujian yang relevan untuk digunakan dalam sistem informasi inputan selanjutnya. Pengujian yang dilakukan pada penelitian ini dapat diandalkan untuk menginformasikan penggunaan model EfficientNetB0 dalam situasi di mana data citra memiliki ukuran 228x228 piksel

Secara keseluruhan, temuan penelitian ini menyoroti pentingnya proses balancing dataset dan rescaling data citra dalam meningkatkan kinerja model, dan menunjukkan keunggulan model EfficientNetB0 dalam mengatasi data citra dengan ukuran tertentu. Hasil pengujian ini dapat dijadikan dasar untuk pengembangan lebih lanjut pada sistem informasi yang memanfaatkan model klasifikasi kanker kulit berdasarkan ukuran citra yang relevan.

Penelitian sebelumnya menghasilkan akurasi terkait klasifikasi kanker kulit. Menurut penelitian oleh Marques et al. (2022), model EfficientNetB0 mencapai akurasi sebesar 97,72% dengan menggunakan dataset dari USA National Institutes of Health. Penelitian dari (Nurlitasari et al., 2022) menghasilkan akurasi yang sangat tinggi, yaitu 99,50%, dengan menggunakan model CNN 2D dan dataset dari International Skin Imaging Collaboration. Sementara itu, penelitian oleh (Nugroho & Puspaningrum, 2021) mengaplikasikan model CNN-ELM dan mencapai akurasi sebesar 93,59% dengan menggunakan dataset Kaggle Melanoma. Hasil-hasil ini memberikan gambaran tentang efektivitas berbagai model dan dataset yang digunakan dalam mengatasi permasalahan klasifikasi kanker kulit. Selain itu tabel 6 menunjukkan perbandingan kinerja antara model EfficientNetB0 saat menggunakan dataset yang berbeda, dan hasilnya menunjukkan bahwa akurasi model tidak terlalu dipengaruhi oleh



dataset yang berbeda. Namun, pada kasus lainnya, perbedaan dalam akurasi menjadi lebih jelas karena perbedaan ukuran data citra yang diuji. Dalam penelitian (Nurlitasari et al., 2022) data citra yang diuji memiliki ukuran 64x64, sedangkan dalam penelitian (Nugroho & Puspaningrum, 2021), ukurannya adalah 200x200. Hal ini mempengaruhi performa model dan membuat perbandingan kinerja menjadi lebih relevan dalam klasifikasi citra dan efisiensi waktu.

Model yang dikembangkan juga melibatkan data augmentation sebagai bagian dari data *preprocessing*, mengacu pada penelitian (Gulakala et al., 2022). Hal ini membuat model menjadi lebih baik dalam pengujian dan meningkatkan signifikansi data yang telah direscaling saat diuji. Dengan demikian, penelitian ini membuktikan keberhasilan dalam mengimplementasikan data augmentation sebagai upaya untuk meningkatkan kinerja model dan membuat proses pengujian lebih bermakna.

## SIMPULAN

Penelitian ini menggunakan CNN untuk deteksi dan diagnosis kanker kulit. Efisiensi model EfficientNetB0 melebihi InceptionV3, terbukti dari akurasi dan waktu inferens yang lebih baik. Temuan ini memiliki implikasi penting dalam diagnosis kanker kulit yang efisien dan akurat. Upaya seperti penyeimbangan dataset, penskalaan citra, dan augmentasi data juga berkontribusi pada kinerja model. Implikasinya meluas pada percepatan diagnosis, perawatan yang lebih baik, dan pengembangan alat diagnostik unggul untuk penyakit kanker kulit. Dengan fokus pada efisiensi dan akurasi, penelitian ini berpotensi mendukung upaya deteksi dini dan penanganan kanker kulit secara lebih efektif.

## REFERENSI

- Agyenta, C., & Akanzawon, M. (2022). Skin Lesion Classification Based on Convolutional Neural Network. *Journal of Applied Science and Technology Trends*, 3(01), 14-19. <https://doi.org/10.38094/jastt301121>
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., ... & Ghayvat, H. (2021). CNN variants for computer vision: History, architecture, application, challenges and future scope. *Electronics*, 10(20), 2470. <https://doi.org/10.3390/electronics10202470>
- Duman, E., & Tolan, Z. (2021). Comparing popular CNN models for an imbalanced dataset of dermoscopic images. *Computer Science*, (Special), 192-207. <https://doi.org/10.53070/bbd.990574>
- Fan, C., Chen, M., Wang, X., Wang, J., & Huang, B. (2021). A review on data preprocessing techniques toward efficient and reliable knowledge discovery from building operational data. *Frontiers in Energy Research*, 9, 652801. <https://doi.org/10.3389/fenrg.2021.652801>
- Gulakala, R., Markert, B., & Stoffel, M. (2022). Generative adversarial network based data augmentation for CNN based detection of Covid-19. *Scientific Reports*, 12(1), 19186. <https://doi.org/10.1038/s41598-022-23692-x>
- Haq, D. Z. (2020). Klasifikasi Citra Kanker Kulit Menggunakan Convolutional Neural Network Model Googlenet. In *Universitas Islam Negeri Sunan Ampel Surabaya*.
- Ibrahim, N., Lestary, G. A., Hanafi, F. S., Saleh, K., Pratiwi, N. K. C., Haq, M. S., & Mastur, A. I. (2022). Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(1), 162 – 176. <https://doi.org/10.26760/elkomika.v10i1.162>
- Jignesh Chowdary, G., Punn, N. S., Sonbhadra, S. K., & Agarwal, S. (2020). Face mask detection using transfer learning of inceptionv3. In *Big Data Analytics: 8th International*

- Conference, BDA 2020, Sonapat, India, December 15–18, 2020, Proceedings 8* (pp. 81-90). Springer International Publishing. [https://doi.org/10.1007/978-3-030-66665-1\\_6](https://doi.org/10.1007/978-3-030-66665-1_6)
- Kim, J. H. (2022). Improvement of inceptionv3 model classification performance using chest X-ray images. *Journal of Mechanics in Medicine and Biology*, 22(08), 2240032. <https://doi.org/10.1142/S0219519422400322>
- Marques, G., Ferreras, A., & de la Torre-Diez, I. (2022). An ensemble-based approach for automated medical diagnosis of malaria using EfficientNet. *Multimedia tools and applications*, 81(19), 28061-28078. <https://doi.org/10.1007/s11042-022-12624-6>
- Montalbo, F. J. P., & Alon, A. S. (2021). Empirical analysis of a fine-tuned deep convolutional model in classifying and detecting malaria parasites from blood smears. *KSII Transactions on Internet and Information Systems*, 15(1), 2021. <https://doi.org/10.3837/tiis.2021.01.009>
- Nugroho, B., & Puspaningrum, E. Y. (2021). Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 8(3), 533-538. <https://doi.org/10.25126/jtiik.2021834515>
- Nurkhasanah, N., & Murinto, M. (2022). Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network. *Sainteks*, 18(2), 183–190. <https://doi.org/10.30595/sainteks.v18i2.13188>
- Nurlitasari, D. A., Magdalena, R., & Fu'adah, R. Y. N. (2022). Analisis Performansi Sistem Klasifikasi Kanker Kulit Menggunakan Convolutional Neural Network. *Journal Of Electrical and System Control Engineering*, 5(2), 91-99. <https://doi.org/10.31289/jesce.v5i2.5691>
- Saputro, R. R., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi Penyakit Kanker Kulit Menggunakan Metode Convolutional Neural Network (Studi Kasus: Melanoma). *Journal of Dinda: Data Science, Information Technology, and Data Analytics*, 2(1), 52-57. <https://doi.org/10.20895/dinda.v2i1.349>
- Sarvamangala, D. R., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: a survey. *Evolutionary intelligence*, 15(1), 1-22. <https://doi.org/10.1007/s12065-020-00540-3>
- Sitompul, P., Okprana, H., & Prasetio, A. (2022). Identification of Rice Plant Diseases Through Leaf Image Using DenseNet 201: Identifikasi Penyakit Tanaman Padi Melalui Citra Daun Menggunakan DenseNet 201. *JOMLAI: Journal of Machine Learning and Artificial Intelligence*, 1(2), 143–150.
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- Tian, C., Xu, Y., Zuo, W., Du, B., Lin, C. W., & Zhang, D. (2021). Designing and training of a dual CNN for image denoising. *Knowledge-Based Systems*, 226, 106949. <https://doi.org/10.1016/j.knosys.2021.106949>
- Tuggener, L., Schmidhuber, J., & Stadelmann, T. (2022). Is it enough to optimize cnn architectures on imagenet?. *Frontiers in Computer Science*, 4, 1041703. <https://doi.org/10.3389/fcomp.2022.1041703>
- Yohannes, R., & Al Rivan, M. E. (2022). Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM. *Jurnal Algoritme*, 2(2), 133-144. <https://doi.org/10.35957/algoritme.v2i2.2363>