

Klasifikasi Kanker Kulit Berbasis CNN dengan Metode *Hybrid Preprocessing*

Widhia KZ Oktoeberza

Program Studi Informatika, Fakultas Teknik, Universitas Bengkulu, Indonesia
Jl. W.R Supratman, Kandang Limun, Bengkulu 38371A
Email: widhiakz@unib.ac.id

INFO ARTIKEL

Alamat Web Artikel:

<https://journal.umy.ac.id/index.php/mt/article/view/22675>

DOI:

<https://doi.org/10.18196/mt.v5i2.22675>

Data Artikel:

Diterima:

11 Februari 2024

Direview:

25 Maret 2024

Direvisi:

15 April 2024

Disetujui:

30 April 2024

Korespondensi:

widhiakz@unib.ac.id

ABSTRAK

Kulit dapat mengalami berbagai gangguan kesehatan jika mendapatkan paparan lingkungan luar yang terlalu intens, salah satunya adalah kanker kulit. Untuk itu, deteksi dini sangat diperlukan agar pasien sesegera mungkin mendapatkan penanganan lebih lanjut. Penelitian ini bertujuan untuk klasifikasi kanker kulit *benign* (jinak) dan *malignant* (ganas). Pemanfaatan AI dapat digunakan dalam klasifikasi karena dapat meningkatkan nilai akurasi. Metode *convolutional neural network* (CNN) dilibatkan dalam penelitian ini. Metode CNN dapat mengklasifikasi dengan cepat dan memiliki nilai akurasi yang cukup tinggi tanpa harus mengekstraksi fitur terlebih dahulu. Kontribusi dalam penelitian ini yakni menggunakan metode *hybrid preprocessing* yang terdiri dari CLAHE, *morphological closing* dan *median filter* pada preprocessing data untuk menghilangkan *noise* yang biasanya terdapat pada epidermis kulit berupa rambut-rambut halus. Metode CNN selanjutnya memproses masukan citra dari hasil *preprocessing*, lalu mengklasifikasikan citra kanker kulit menjadi kategori *benign* dan *malignant*. Setelah tahap pengujian sistem berhasil memperoleh hasil yang cukup memuaskan, dengan nilai *accuracy* sebesar 78,19% dan *loss* 0.5324. Kinerja sistem dengan metode yang diusulkan mencapai akurasi yang baik dan cukup mampu diimplementasikan untuk membantu para profesional medis dalam membuat mendiagnosis kanker kulit.

Kata Kunci: Klasifikasi, Kanker Kulit, CNN, *Hybrid Preprocessing*.

ABSTRACT

Skin is the largest external organ that covers the human body. Due to intense exposure to the external environment, the skin can experience various health problems, one of which is skin cancer. Early detection is needed so that further treatment of the patient can be carried out immediately. This study aims to classify Benign and Malignant skin cancer. Utilization of AI can be used in classification because it can increase accuracy values. This research uses the convolutional neural network (CNN) method. The CNN method can classify quickly and has a fairly high accuracy value without having to extract features first. A hybrid preprocessing method, namely CLAHE, Morphological Closing and Median Filter, was used in data preprocessing which aims to remove noise caused by fine hairs that grow along the epidermis of the skin. After the preprocessing process is complete, CNN processes the input image, then classifies the input into the categories of benign skin cancer or malignant skin cancer. After the testing stage, the system succeeded in obtaining quite satisfactory results, with an accuracy value of 78.19% and a loss of 0.5324. The performance of the proposed system succeeded in achieving better accuracy compared to previous research with much smaller data. These test results show that the proposed method and model are quite capable of assisting medical professionals in making a diagnosis of skin cancer.

Keywords: Classification, Skin Cancer, CNN, *Hybrid Preprocessing Method*.

1. PENDAHULUAN

Kulit adalah bagian tubuh manusia yang terkena sinar matahari secara langsung karena kulit merupakan lapisan terluar dari tubuh. Paparan sinar matahari yang berlebihan tentu berbahaya bagi kulit karena dapat menyebabkan kanker kulit. Data statistik GLOBOCAN 2020 dari *World Health Organization* menyebutkan total kematian akibat kanker di dunia mencapai 9,9 juta jiwa. Angka tersebut menunjukkan bahwa kanker merupakan salah satu penyebab utama kematian di dunia.

Benjolan atau pertumbuhan yang berlebihan jaringan kulit yang mengenai sebagian atau seluruh lapisan kulit disebut kanker kulit. Struktur kanker kulit ini tidak teratur, dengan diferensiasi sel di kromatin, nukleus, dan sitoplasma pada berbagai tingkatan. Kanker kulit tumbuh dan menyerap dengan cepat, merusak jaringan sekitarnya dan bermetastasis melalui pembuluh darah dan atau pembuluh getah bening [1]. Dengan menggunakan Biopsi, dokter kulit biasanya mendiagnosa kanker kulit dengan mengambil sampel kecil jaringan kulit lalu diperiksa di laboratorium. Biopsi sangat mahal dan dapat melukai atau menggores kulit manusia. Berbagai jenis kanker kulit termasuk *Actinic Keratosis* (akiec), *Basal Cell Carcinoma* (bcc), *Benign Keratosis* (bkl), *Dermatofibroma* (df), *Melanotic Nevi* (nv), *Melanoma* (mel), *Vascular* (vasc)[2].

Diagnosis melanoma ganas pada pasien sangat penting untuk mencegah kanker bermetastasis ke organ lain karena penelitian menunjukkan bahwa deteksi dan pengobatan dini meningkatkan kemungkinan pasien sembuh [3]. Ada banyak metode dan pendekatan untuk mendeteksi penyakit kanker. Namun, dengan perkembangan zaman saat ini, pendekatan lama telah ditinggalkan dan metode baru seperti pembelajaran mesin, pembelajaran mendalam, pembelajaran transfer, dan metode lainnya digunakan. Metode deteksi dan klasifikasi juga beragam.

Dengan menggunakan pembelajaran mendalam pada olah gambar, solusi yang didasarkan pada kecerdasan buatan (AI) dapat membantu pekerja medis melakukan pemeriksaan dan klasifikasi jenis kanker. Kemampuan model ini untuk mengenali pola dengan menggunakan fitur gambar yang dimilikinya secara akurat memungkinkan solusi AI ini untuk melakukannya. Selain itu, karena model ini memiliki akurasi yang tinggi, kemungkinan kanker kulit pada pasien dapat diketahui dengan cepat [4].

Beberapa penelitian mengenai klasifikasi kanker kulit berbasis AI sudah dilakukan. Pada sebuah penelitian dilakukan deteksi kanker kulit menggunakan *convolutional neural network* (CNN) dan SVM, kelas dibagi menjadi 2 yaitu *benign* dan *malignant* dengan akurasi sebesar 65,67% [2]. Penelitian lain menggunakan metode klasik CNN dengan *preprocessing* data menggunakan *augmentasi*, dengan menggunakan CNN, menggunakan teknik augmentasi yang tepat sangat diperlukan untuk membantu menaikkan nilai akurasi, nilai akurasi yang di dapatkan sebesar 75%. Penelitian berikutnya adalah klasifikasi kanker kulit dengan menggunakan metode KNN dan SVM, dengan fitur tekstur warna paling baik pada algoritme KNN dengan nilai $K = 5$, metode ini menghasilkan akurasi sebesar 70,61% [5].

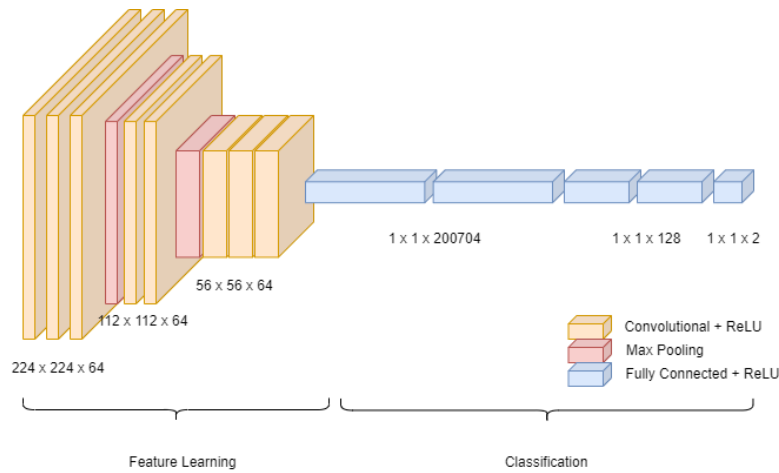
CNN adalah teknik klasifikasi yang dapat digunakan untuk klasifikasi citra digital, khususnya gambar kanker kulit. Diharapkan bahwa teknik ini akan membantu dokter mendiagnosis kanker kulit pada lapisan epidermis dengan lebih akurat dan membuat keputusan pengobatan yang tepat [4]. Berdasarkan penelitian serupa, pada penelitian ini digunakan metode CNN dibandingkan dengan penelitian sebelumnya. Selain itu, penelitian ini menambahkan teknik dengan menggunakan filter median, CLAHE, dan *closing morphology*. Semua penggunaan ini berkontribusi pada pengurangan derau pada masukan gambar yang disebabkan oleh rambut halus, serta penyeragaman ukuran gambar sebagai masukan. Dengan demikian, hasil penelitian ini lebih akurat daripada penelitian sebelumnya.

2. METODE PENELITIAN

2.1. *Convolutional Neural Network* (CNN)

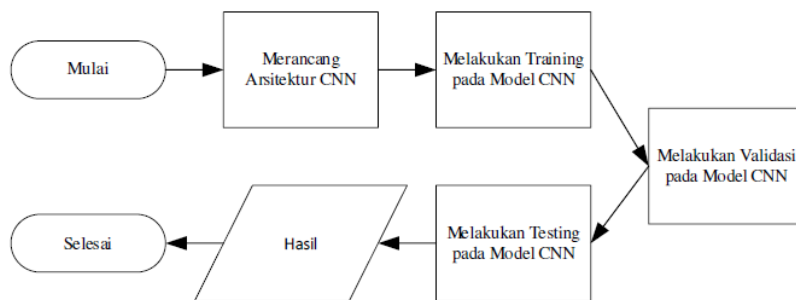
Salah satu pendekatan deep neural network (CNN) yang memiliki akurasi pengakuan gambar yang tinggi adalah CNN. CNN, yang merupakan evolusi dari multilayer perceptron (MLP), memproyeksikan data dua dimensi pada neuronnya [4]. CNN terdiri dari beberapa lapisan (layer), termasuk lapisan konvolusi, lapisan pooling, dan lapisan yang benar-benar terhubung, yang bekerja secara hierarki, sehingga masukan dari lapisan sebelumnya akan ditransmisikan ke lapisan berikutnya [2].

2.2. Arsitektur CNN



Gambar 1. Arsitektur Pemodelan CNN


Gambar 1 merupakan arsitektur pemodelan klasifikasi yang digunakan. Tidak diperlukannya metode ekstraksi khusus dalam proses klasifikasi, merupakan salah satu keunggulan dari metode CNN sehingga performanya menjadi lebih cepat. Hanya saja, jumlah data yang jauh lebih besar dibutuhkan oleh CNN untuk proses pelatihan. Dalam hal ini juga diperlukan unit pemrosesan grafik yang mahal untuk melatih sistem sehingga upaya komputasi pun juga meningkat. Untuk alur CNN dapat dilihat pada Gambar 2.



Gambar 2. Alur CNN [6]

1. Konvolusi

Lapisan konvolusi melakukan fungsi matematika dengan menggunakan kernel secara iteratif [6]. Lapisan ini menggunakan *string* yang disebut kernel yang diterapkan pada input yang disebut tensor (juga disebut *string*) untuk mengekstrak gambar input. Ini menghasilkan nilai yang dikenal sebagai transformasi linier, yang mengandung informasi spasial. Metode ini menggunakan proses iteratif, yang berarti banyak *field* berulang. Proses konvolusi disajikan pada Gambar 3.



Gambar 3. Proses Konvolusi [6]

2. *Padding*

Penambahan ukuran piksel dengan nilai tertentu untuk mengisi celah hasil konvolusi dari awal hingga akhir [7]. Untuk memastikan bahwa keluaran konvolusi tidak memiliki perbedaan dimensi yang signifikan dari dimensi masukan, nilai yang biasanya digunakan adalah nol, atau padding zero.

3. *Fungsi Aktivasi*

Dilakukan setelah proses konvolusi selesai. Salah satu jenis persamaan yang dapat digunakan dalam operasi ini adalah perbaikan unit linier (ReLU), yang meningkatkan representasi model dan menjalankan fungsi non-linier [7]. Jika inputnya negatif, fungsi aktivasi ReLU akan menghasilkan *output* nol. Jika nilai masukan positif, nilai keluaran akan sama dengan nilai masukan.

4. *Lapisan Pooling*

Untuk mengurangi jumlah fitur yang diekstraksi dari suatu gambar, lapisan penyatuan atau pooling menggunakan kernel dalam proses pengurangan piksel gambar [8]. Pada awalnya, gambar masukan diisi dengan nol jika ukurannya lebih kecil dari ukuran kernel yang digunakan.

5. *Dropout*

Dalam proses pelatihan, *dropout* digunakan dengan menghilangkan sejumlah neuron secara acak. Setiap neuron memiliki probabilitas yang sama. Proses ini dimaksudkan untuk meningkatkan kinerja network dengan mengurangi beban komputasi [9].

6. *Confusion Matrix*

Confusion matrix membandingkan informasi kelas yang seharusnya dengan hasil klasifikasi yang dihasilkan [10].

2.3. Dataset dan *hybrid method Preprocessing*

1. *Dataset*

Dataset yang digunakan adalah dataset sekunder yang bersumber dari Kaggle [11] dengan jumlah data sebanyak 1530. dengan 980 data *train* yang dibagi menjadi 480 data *benign* dan 500 data *malignant*. Serta sebanyak 550 data test dengan pembagian sebanyak 250 data *benign* dan 300 data *malignant*.

2. *Preprocessing*

Dataset yang ada masih mentah dan belum melalui data *preprocessing*, sehingga masih banyak data yang memiliki *noise* yang tumbuh di lapisan epidermis kulit berupa rambut-rambut halus. Data *preprocessing* dilakukan dengan tujuan menghilangkan *noise* tersebut. Adapun *hybrid method preprocessing* yang akan dilakukan adalah sebagai berikut: CLAHE [12], Morphological closing [13], Median Filter [14].


3. **HASIL DAN PEMBAHASAN**

Pada penelitian ini, teknik *deep learning* (CNN) digunakan untuk mengklasifikasikan kanker kulit *benign* dan *malignant*. Dataset yang digunakan adalah dataset yang diambil dari dosen pengampu mata kuliah dengan jumlah data sebanyak 980 data *train* yang dibagi menjadi 480 data *benign* dan 500 data *malignant*. Serta sebanyak 550 data *test* dengan pembagian sebanyak 250 data *benign* dan 300 data *malignant*. Dalam mengklasifikasi penyakit kanker kulit ini, tahapan diawali dengan *preprocessing* data kemudian dilakukan dengan *training* model, dan validasi model.

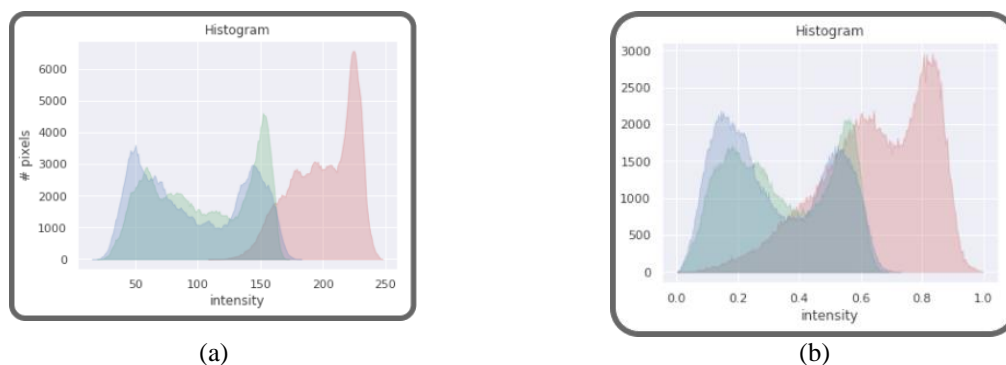
3.1. *Preprocessing dan Struktur CNN*

Perancangan arsitektur CNN yang akan digunakan dalam penelitian ini dilakukan, yaitu dengan mengkonfigurasi parameternya. Parameter yang digunakan meliputi dua lapisan konvolusi (Conv2D), dua lapisan campuran (MaxPooling2D) yang diletakkan setelah lapisan konvolusi

(Conv2D), satu lapisan *flatten*, dua lapisan *dense*, dan satu lapisan *dropout*.. Sebelum melakukan proses training data dataset sebelumnya dilakukan pengolahan yaitu preprocessing data, preprocessing data dilakukan dengan menggunakan CLAHE, morphological closing, dan median filter. CLAHE mengatur tingkat kontras citra sehingga warna rambut halus pada kulit akan semakin terlihat seperti pada Gambar 4. CLAHE juga bekerja dengan menyeimbangkan histogram pada citra. Gambar 5 menunjukkan perbandingan histogram citra.




Gambar 4. (a) Citra Original, (b) Citra Hasil CLAHE



Gambar 5. (a) Histogram Citra Original, (b) Histogram Citra CLAHE

Pada Gambar 5 terlihat bahwa histogram citra original mengalami perubahan setelah dilakukan CLAHE, histogram yang tinggi disesuaikan dengan sedikit diturunkan dan histogram yang rendah ditingkatkan. Histogram menjadi lebih merata setelah preprocessing dengan CLAHE. Kemudian setelah CLAHE dilakukan proses *morphological closing* dilakukan, yaitu dengan melakukan proses erosi disusul proses dilasi. Erosi bekerja dengan mengurangi beberapa *pixel* tertentu sedangkan dilasi bekerja dengan menambah *pixel* tertentu. *Morphological closing* menghilangkan rambut halus pada kulit seperti terlihat pada Gambar 6.




Gambar 6. Citra Hasil *Morphological Closing*

Selanjutnya *median filter* berperan untuk menghilangkan *noise* dan menghaluskan kulit. Hasil dari median filter tersaji pada Gambar 7. Terlihat pada Gambar 7 bahwasanya *median filter*

Oktoberza

Klasifikasi Kanker Kulit Berbasis CNN dengan Metode Hybrid Preprocessing

membuat gambar menjadi lebih halus, dan mengurangi *noise* yang timbul akibat penyesuaian kontras dan penghilangan *pixel* pada proses sebelumnya.



Gambar 7. Citra Hasil Median Filtering


Setelah *preprocessing* data dilakukan, data selanjutnya bisa dilatih pada model CNN yang sudah dibuat arsitekturnya. Gambar 8 menunjukkan model *summary* yang digunakan pada arsitektur ini. Dari model *summary* ini, kita dapat mengetahui bahwa terdapat 25,729,218 parameter yang dapat dipelajari.

```
Model: "sequential_1"
-----
Layer (type)                Output Shape              Param #
-----
conv2d_2 (Conv2D)           (None, 224, 224, 64)     1792
max_pooling2d_2 (MaxPooling (None, 112, 112, 64)    0
2D)
dropout_2 (Dropout)         (None, 112, 112, 64)     0
conv2d_3 (Conv2D)           (None, 112, 112, 64)     36928
max_pooling2d_3 (MaxPooling (None, 56, 56, 64)      0
2D)
dropout_3 (Dropout)         (None, 56, 56, 64)      0
flatten_1 (Flatten)         (None, 200704)           0
dense_2 (Dense)              (None, 128)              25690240
dense_3 (Dense)              (None, 2)                258
-----
Total params: 25,729,218
Trainable params: 25,729,218
Non-trainable params: 0
```

Gambar 8. Model *Summary* CNN

3.2. Hasil *Training* dan *Validasi*


Gambar 9 (a) menunjukkan hasil pelatihan dan validasi yang diperoleh dari struktur CNN yang dirancang. Pada Gambar 9 (a) terlihat model akurasi dari data *train* mencapai angka 0,80 pada *epoch* ke 50 dan mengalami peningkatan setiap *epoch*. Begitu juga dengan data validasi akurasi juga meningkat pada tiap *epoch* dan beriringan dengan data *train* hingga mencapai nilai akurasi sebesar 0,77. Hasil *training* data validasi berhenti mengalami peningkatan pada *epoch* ke 20. Hal ini diakibatkan karena *dataset* yang kurang banyak sehingga mesin menjadi rancu. Namun dapat disimpulkan hasil dari *training* model, model ini sudah cukup mendapat hasil yang memuaskan dengan model yang sudah mencapai *fitmodel*.



Gambar 9. Grafik Hasil Training (a) Grafik Akurasi, (b) Grafik Loss

Gambar 9 (b) merupakan grafik dari *loss* model, nilai *loss* menunjukkan tingkat *error* atau kesalahan mesin ketika belajar mengklasifikasi data *train* dan data validasi. Terlihat bahwa nilai *loss* dari data *train* di bawah 0,6 dan data validasi di atas 0,6. Nilai *loss* dapat diturunkan kembali dengan memperbanyak data *train* dan data *test*.

1. Hasil Testing



Gambar 10. Confusion Matrix Hasil Testing

Pada Gambar 10, *confusion matrix* dari hasil *testing* yang memprediksi data validasi ke dalam model. *Confusion matrix* menunjukkan tingkat kebingungan mesin pada model. Pada *confusion matrix* di atas dapat dilihat bahwa nilai dari *true positive* (TP) adalah 169. Kemudian nilai *true negative* (TN) adalah 226, lalu nilai *false positive* (FP) adalah 74 dan *false negative* (FN) adalah 81.

Nilai *precision*, *accuracy*, dan *recall* model dapat dihitung dari *confusion matrix*. Untuk menghitung hal tersebut, rumus berikut digunakan [15]. Hasil perhitungan menunjukkan nilai *accuracy* 0,78, *precision* 0,6954, dan *recall* 0,676.

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

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

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

2. Hasil Evaluasi

Selama proses evaluasi, hasil pelatihan, validasi, dan pengujian model dievaluasi. Hasilnya adalah sebagai berikut:

a. Epoch

Hasil dari perbedaan nilai hasil pelatihan dan validasi model menunjukkan bahwa epoch mempengaruhi akurasi yang diperoleh. Akurasi berkorelasi positif dengan jumlah epoch yang ada. Namun, pada epoch 50 ke atas, model yang dibangun dalam penelitian ini berhenti belajar dan tidak lagi lebih akurat.

b. Learning Rate

Learning rate yang digunakan di awal adalah sebesar 0.00001, *learning rate* terus diturunkan seiring proses *training* berjalan agar data dapat tercakup semua secara maksimal dan model belajar dengan baik.

c. Hasil Terbaik

Tabel 1 menunjukkan hasil terbaik yang diperoleh setelah melakukan analisis terhadap pelatihan, validasi, dan pengujian.

Tabel 1. Hasil Evaluasi Klasifikasi

Hasil Evaluasi	Value
Accuracy	0.7819
Val_accuracy	0.5324
Val_loss	0.7602
Prediction	0.7755

Pada Tabel 1 dapat dilihat nilai dari *training* diperoleh *accuracy* 0.7819, *validation accuracy* 0.7602, *training loss* 0.5324, *validation loss* 0.204458 dengan *training elapsed time* 204.150 detik dan *testing accuracy* sebesar 0.7755 dengan *evaluation elapsed time* 209.890 detik pada *epoch* ke 50. Waktu inferensi rata-rata per sampel dari model ini adalah 0.00252 detik. Hasil ini lebih baik dibanding penelitian sejenis yang menggunakan KNN dengan *accuracy* 75% dan CNN 76,56% [16].

4. KESIMPULAN

Studi ini bertujuan untuk mengklasifikasikan kanker kulit menjadi dua kategori: jinak dan ganas. Data yang digunakan berasal dari Kaggle, dengan total 1530 data, yang terdiri dari 980 data latih dan 550 data uji. Dengan akurasi 78,19% dan *loss* 0,5324, waktu yang dibutuhkan dalam menyelesaikan *training* adalah 204.150 detik dan waktu inferensi rata-rata per sampel dari model ini adalah 0.00252 detik, metode CNN menghasilkan hasil klasifikasi yang cukup baik. Untuk meningkatkan kinerja klasifikasi yang diharapkan, penelitian selanjutnya dapat menggunakan lebih banyak data dan metode deep learning lainnya.

DAFTAR PUSTAKA

- [1] S. Wilvestra, S. Lestari, and E. Asri, "Retrospective Study of Skin Cancer at The Dermatology and Venerology clinic Dr. M. Djamil Padang 2015-2017," *J. Kesehatan Andalas*, vol. 7, no. Supplement 3, pp. 47–49, 2018.
- [2] R. Yohannes and M. E. Al Rivan, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," *J. Algoritma*, vol. 2, no. 2, pp. 133–144, 2022, doi: 10.35957/algoritme.v2i2.2363.
- [3] M. K. Soegeng, L. Liliana, and A. Noertjahyana, "Penerapan Convolutional Neural Network untuk Klasifikasi Kanker Kulit Melanoma pada Dataset Gambar Kulit," *J. Infra*, vol. 9, no. 1, pp. 47–51, 2021, [Online]. Available: <https://publication.petra.ac.id/index.php/teknik-informatika/article/view/10945>

- [4] Sofia Saidah, I. P. Y. N. Suparta, and E. Suhartono, "Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 11, no. 2, pp. 148–153, 2022, doi: 10.22146/jnteti.v11i2.2739.
- [5] L. Hakim, Z. Sari, and Handhajani, "Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network," *Resti*, vol. 5, no. 2, pp. 379–385, 2017.
- [6] R. R. Saputro, A. Junaidi, and W. A. Saputra, "Klasifikasi Penyakit Kanker Kulit Menggunakan Metode Convolutional Neural Network," vol. 2, no. 1, pp. 52–57, 2022.
- [7] E. N. Arrofiqoh and H. Harintaka, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi," *Geomatika*, vol. 24, no. 2, pp. 61–68, 2018.
- [8] C. A. Dias *et al.*, "Using the Choquet integral in the pooling layer in deep learning networks," in *North american fuzzy information processing society annual conference*, 2018, pp. 144–154.
- [9] A. Poernomo and D.-K. Kang, "Biased dropout and crossmap dropout: learning towards effective dropout regularization in convolutional neural network," *Neural networks*, vol. 104, pp. 60–67, 2018.
- [10] R. Herwanto, K. Gunadi, and E. Setyati, "Pengenalan Golongan Jenis Kendaraan Bermotor pada Ruas Jalan Tol Menggunakan CNN," *J. Infra*, vol. 8, no. 1, pp. 196–202, 2020.
- [11] C. Fanconi, "Skin Cancer: Malignant vs. Benign," 2019.
- [12] S. Saifullah, "Analisis Perbandingan HE Dan CLAHE Pada Image Enhancement Dalam Proses Segmenasi Citra Untuk Deteksi Fertilitas Telur," *J. Nas. Pendidik. Tek. Inform.*, vol. 9, no. 1, p. 134, 2020, doi: 10.23887/janapati.v9i1.23013.
- [13] A. Juliana and A. Triayudi, "Implementasi Morphological Filtering Untuk Penajaman Citra CCTV," *ProTekInfo(Pengembangan Ris. dan Obs. Tek. Inform.)*, vol. 1, no. September, pp. 71–75, 2017, doi: 10.30656/protekinfo.v1i0.36.
- [14] I. Maulana and P. N. Andono, "Analisa Perbandingan Adaptif Median Filter Dan Median Filter Dalam Reduksi Noise Salt & Pepper," *CogITo Smart J.*, vol. 2, no. 2, pp. 157–166, 2016, doi: 10.31154/cogito.v2i2.26.157-166.
- [15] N. P. Lestari, "Uji Recall and Precision Sistem Temu Kembali," *Univ. Airlangga*, vol. 5, no. 3, pp. 45–46, 2016, [Online]. Available: <http://journal.unair.ac.id/LN@uji-recall-and-precision-sistem-temu-kembali-informasi-opac-perpustakaan-its-surabaya-article-10825-media-136-category-8.html>
- [16] T. R. Savera, W. H. Suryawan, and A. W. Setiawan, "Deteksi Dini Kanker Kulit menggunakan K-NN dan Convolutional Neural Network," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 2, pp. 373–378, Feb. 2020, doi: 10.25126/jtiik.2020702602.