

## Pendekatan Multi-Input dalam Deteksi Kanker Kulit: Implementasi EfficientNetV2-B2 dan LightGBM

M. Azka Khoirul Ibad<sup>1,\*</sup>, Sri Winarno<sup>1</sup>

<sup>1</sup> Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Indonesia

\* Correspondence: 111202113517@mhs.dinus.ac.id

**Copyright:** © 2025 by the authors

Received: 10 Maret 2025 | Revised: 15 Maret 2025 | Accepted: 25 Maret 2025 | Published: 15 April 2025

### Abstrak

Kanker kulit merupakan salah satu jenis kanker dengan tingkat prevalensi yang tinggi, sehingga deteksi dini sangat penting untuk meningkatkan peluang kesembuhan. Penelitian ini bertujuan untuk mengembangkan model deteksi kanker kulit yang menggabungkan data citra dan data tabular menggunakan EfficientNetV2-B2 untuk ekstraksi fitur citra dan LightGBM untuk *estimator* prediksi data tabular. Dataset ISIC 2024 yang digunakan terdiri dari 401.059 citra lesi kulit dengan fitur tabular, termasuk usia, jenis kelamin, lokasi, diameter, dan bentuk lesi. Data tabular diproses dengan *normalisasi* dan *encoding* untuk menghindari bias. Data citra juga diproses dengan teknik augmentasi dari *kerascv*. Model *multi-input* ini menggabungkan fitur citra dan tabular menggunakan teknik *concatenation*, dengan lapisan *dense* sebagai *output* akhir. Hasil temuan kami menunjukkan bahwa akurasi dan nilai AUC model mencapai 96% dan 98%, dengan keberhasilan dalam menangani ketidakseimbangan kelas menggunakan teknik *undersampling* dan *oversampling*. Penelitian ini menunjukkan bahwa kombinasi citra dan data tabular meningkatkan akurasi deteksi kanker kulit sebesar 2%, dibandingkan dengan model CNN konvensional yang hanya mencapai akurasi sekitar 94%. Selain itu, menawarkan efisiensi komputasi yang lebih baik dibandingkan dengan model CNN konvensional. Kontribusi utama penelitian ini adalah penggunaan *multi-input* yang melengkapi informasi visual dengan data klinis untuk deteksi kanker kulit yang lebih akurat dan efisien.

**Kata kunci:** algoritma cnn; deteksi dini; efficientnetv2; fitur *multi-input*; kanker kulit

### Abstract

*Skin cancer is one of the types of cancer with a high prevalence rate, so early detection is very important to increase the chances of recovery. This study aims to develop a skin cancer detection model that combines image data and tabular data using EfficientNetV2-B2 for image feature extraction and LightGBM for tabular data prediction estimation. The ISIC 2024 dataset used consists of 401,059 images of skin lesions with tabular features, including age, gender, location, diameter, and shape of the lesions. Tabular data is processed with normalization and encoding to avoid bias. Image data is also processed with augmentation techniques from kerascv. This multi-input model combines image and tabular features using concatenation techniques, with a dense layer as the final output. Our findings show that the model's accuracy and AUC value reached 96% and 98%, with success in handling class imbalance using undersampling and oversampling techniques. This study shows that the combination of images and tabular data increases the accuracy of skin cancer detection by 2%, compared to conventional CNN models, which only achieve an accuracy of around 94%. Moreover, this model offers better computational efficiency compared to conventional CNN models. The main contribution of this research is the use of multi-input that complements visual information with clinical data for more accurate and efficient skin cancer detection.*

**Keywords:** *cnn algorithm; early detection; efficientnetv2; multi-input features; skin cancer*



## PENDAHULUAN

Kanker kulit adalah masalah kesehatan serius yang mempengaruhi orang di seluruh dunia (Ieracitano et al., 2025). Kanker kulit adalah bentuk kanker yang sangat ganas dan berbahaya (Akinrinade & Du, 2025). Berdasarkan data GLOBOCAN 2020, tercatat sekitar 1.2 juta kasus baru kanker kulit *non-melanoma*, dengan 63.731 kematian akibat penyakit ini secara global. Selain itu, *melanoma* kulit menyumbang 324.635 kasus baru, dengan 57.043 kematian (Sung et al., 2021). Setiap tahun, sekitar satu juta kasus kanker kulit *non-melanoma* terdeteksi di Amerika Serikat, sebanyak 95% pasien yang mengidap penyakit ini memiliki peluang bertahan hidup selama lima tahun atau lebih, meski kasus terus meningkat, angka kematian masih konsisten rendah (Yogiswara et al., 2021). Kanker kulit menempati urutan ketiga sebagai jenis kanker paling umum di Indonesia, menunjukkan tingginya urgensi dalam penanganan penyakit ini (Pratama et al., 2021).

Faktor risiko utama dalam perkembangan kanker kulit meliputi paparan *radiasi ultraviolet* (UV), predisposisi genetik, gaya hidup yang tidak sehat, serta kebiasaan merokok (Hameed et al., 2024). Paparan UV yang berlebihan merupakan faktor risiko utama dalam perkembangan kanker kulit. Sinar UV dapat merusak DNA pada sel kulit, yang berpotensi menyebabkan mutasi genetik dan perkembangan sel kanker (Adzhani et al., 2022). Indonesia, sebagai negara tropis yang terletak di garis khatulistiwa, menerima paparan sinar matahari yang tinggi sepanjang tahun (Oktora et al., 2023). Secara patofisiologis, kanker kulit berkembang akibat mutasi genetik yang mengakibatkan ketidakmampuan *gen repair* dalam memberikan sinyal untuk melakukan perbaikan pada kulit yang terpapar agen yang dapat merusak sel (Tarisa et al., 2022).

Jenis kanker kulit dapat diklasifikasikan kedalam *malignant* (ganas) dan *benign* (jinak). Metode diagnosis yang umum digunakan untuk mendeteksi kanker kulit adalah biopsi, yang melibatkan pengambilan sampel jaringan kulit untuk analisis laboratorium. Meskipun akurat, prosedur ini memiliki beberapa keterbatasan, seperti biaya yang tinggi (Faruk & Nafi'iyah, 2020), infeksi, pendarahan, atau pembentukan jaringan parut. Risiko ini dapat meningkat tergantung pada lokasi dan ukuran lesi yang diambil sampelnya. Jika sampel biopsi terlalu kecil atau tidak mencakup area lesi yang paling mencurigakan, hasilnya mungkin tidak memberikan diagnosis yang akurat (Kingsley., 2023).

Pendekatan berbasis *Artificial Intelligence* (AI) telah mengalami perkembangan pesat dalam klasifikasi citra medis dalam beberapa tahun terakhir. *Convolutional Neural Network* (CNN) menjadi solusi utama dalam deteksi kanker kulit karena kemampuannya yang efektif dalam menganalisis dan mengklasifikasikan gambar secara efektif (Bintang & Imaduddin, 2024). Penelitian sebelumnya yang dilakukan oleh Hakim et al. (2021) menggunakan dataset ISIC 2018 dengan 10.000 citra dermoskopi mencapai akurasi sebesar 75%. Penelitian lain yang dilakukan oleh Claret et al. (2024) dengan dataset HAM10000, yang memiliki variasi citra yang lebih luas, berhasil memperoleh akurasi hingga 94%. Model VGG-16 yang dilatih pada 6.594 citra juga menunjukkan performa tinggi dengan akurasi 93,18% (Hasan et al., 2021). Meskipun demikian, pendekatan berbasis CNN masih memiliki tantangan, seperti risiko *overfitting*, dan kebutuhan komputasi yang tinggi.

Sebagai solusi untuk meningkatkan kinerja model dalam klasifikasi kanker kulit, penelitian ini mengusulkan pendekatan *multi-input* yang menggabungkan model EfficientNetV2-B2 sebagai ekstraksi fitur untuk citra dan LightGBM sebagai *estimator* prediksi untuk data tabular. Keterbatasan pendekatan sebelumnya, yang meliputi ketergantungan tinggi pada citra saja yang dapat menurunkan akurasi pada kasus dengan citra kurang jelas, serta masalah komputasi yang lambat, dapat diatasi dengan informasi tambahan dari data tabular. EfficientNetV2 dipilih sebagai model utama karena menawarkan kecepatan pelatihan yang lebih tinggi serta efisiensi parameter yang lebih baik dibandingkan pendahulunya. Model ini dikembangkan dengan memanfaatkan eksplorasi ruang pencarian

yang diperluas, termasuk penggunaan operasi baru seperti Fused-MBConv untuk meningkatkan kinerja jaringan (Huang & Liao, 2023; Ichwan & Hadi, 2023). LightGBM, di sisi lain, memiliki keunggulan dalam menangani dataset besar dan tidak seimbang melalui teknik *Gradient-Based One-Side Sampling* (GOSS), yang mempertahankan sampel dengan loss tertinggi untuk meningkatkan efisiensi pelatihan (Nisa et al., 2024). Pendekatan ini sejalan dengan penelitian sebelumnya, yang menunjukkan bahwa kombinasi CNN dan teknik *ensemble learning* dapat meningkatkan akurasi deteksi penyakit, seperti pada kasus kanker paru-paru dan usus besar yang akurasinya mencapai 99% (Akhter et al., 2022). Kombinasi ini memungkinkan pemanfaatan informasi metadata pasien, seperti usia, jenis kelamin, bentuk lesi, ukuran lesi, diameter lesi dan lokasi lesi, yang dapat memberikan konteks tambahan dalam klasifikasi kanker kulit.

Pada penelitian sebelumnya masih kurang dalam mengeksplorasi integrasi antara data citra dan data tabular dalam klasifikasi kanker kulit (Akhter et al., 2022). Sebagian besar penelitian hanya mengandalkan CNN untuk analisis citra tanpa memanfaatkan metadata yang dapat memberikan wawasan tambahan mengenai karakteristik pasien dan lesi. Selain itu, masih terdapat tantangan dalam mengurangi risiko *overfitting* dan mengoptimalkan efisiensi komputasi. Pendekatan *multi-input* yang diusulkan dalam penelitian ini bertujuan untuk mengatasi keterbatasan tersebut dengan memanfaatkan fitur numerik dari metadata pasien.

Penelitian ini bertujuan untuk mengimplementasikan pendekatan *multi-input* dengan menggabungkan EfficientNetV2 dan LightGBM guna mengoptimalkan klasifikasi kanker kulit. Kontribusi dari penelitian ini terletak pada integrasi informasi visual dan metadata untuk meningkatkan keakuratan deteksi serta mengurangi ketergantungan pada prosedur diagnosis dengan menggunakan biopsi. Dengan demikian, penelitian ini diharapkan dapat memberikan solusi yang lebih efisien dan dapat diadopsi secara luas dalam sistem deteksi kanker kulit berbasis AI.

## METODE

Tahapan penelitian ini dimulai dengan pengumpulan data, data yang digunakan pada penelitian ini diperoleh dari ISIC 2024 dari laman Kaggle. Dataset ini terdiri dari 401.059 citra lesi kulit dan data tabular yang terbagi dalam dua kelas *benign* dan *malignant*. Citra dalam dataset ini diambil dari 3D Total Body Photography (TBP) menggunakan alat *Vectra WB360*, hasilnya adalah potongan lesi individu dengan *field-of-view* sebesar 15x15 mm. Citra tersebut disimpan dalam format *byte string* untuk efisiensi penyimpanan dan pemrosesan, karena format ini lebih mengkonsumsi lebih sedikit memori dibandingkan representasi *np.array*.

Setelah data dikumpulkan tahapan selanjutnya data akan dilakukan *preprocessing* dengan cara mengelompokkan kolom numerik dan kategorikal, lalu pembersihan data yang terdapat *missing value* dan duplikasi data. Normalisasi pada fitur numerik juga dilakukan untuk meningkatkan stabilitas model. Fitur kategorikal juga diubah menjadi representasi numerik menggunakan *One-Hot Encoding* guna menghindari bias dalam interpretasi model. Setelah melalui tahap *preprocessing*, masuk ke tahap penyelesaian masalah di ketidakseimbangan dataset. Dataset awalnya menunjukkan ketidakseimbangan signifikan antara kelas *benign* dan *malignant*. Kombinasi *undersampling* dan *oversampling* menggunakan *random under sampler* dan *pandas* diterapkan untuk mengatasi ketidakseimbangan dataset tersebut.

Augmentasi citra diterapkan guna meningkatkan keberagaman data dengan menggunakan *KerasCV*. Ukuran citra kemudian diubah dari 225x225 menjadi 128x128 piksel, guna mengurangi beban komputasi. Augmentasi hanya diterapkan pada data train, sedangkan data validasi tidak diterapkan augmentasi guna memastikan evaluasi yang tidak bias. Sebelum masuk ke tahapan modelling, data akan dibagi menjadi dua yaitu data train sebesar 80% dan data valid sebesar 20%.

*Modelling* dilakukan dengan menerapkan *pre-trained* CNN model bernama EfficientNetV2-B2, yang dikombinasikan dengan model tabular LightGBM. Probabilitas prediksi dari LightGBM digunakan sebagai fitur tambahan dalam CNN. LightGBM dikonfigurasi dengan *boosting\_type* gbdt, *max\_depth* 7, dan *num\_leaves* 239. EfficientNetV2 Imagenet dipilih karena memiliki arsitektur yang lebih efisien, menggunakan kombinasi MBConv dan Fused-MBConv, serta penyesuaian *receptive field* untuk meningkatkan akurasi dengan jumlah parameter yang lebih sedikit (Tan & Le, 2021), Dropout 0.2 diterapkan untuk mencegah *overfitting*. Tahapa terakhir merupakan evaluasi dalam penelitian ini, evaluasi ini bertujuan untuk mengetahui kinerja model prediksi dengan menggunakan *confusion matrix* yang akan memberikan nilai *accuracy* (1), *precision* (2), *recall* (3), dan *F1-Score* (4). *Accuracy* mengukur kebenaran prediksi secara keseluruhan, sementara *precision* dan *recall* memberikan informasi lebih rinci tentang ketepatan model dalam mendeteksi kelas positif dan seberapa banyak kelas positif yang berhasil terdeteksi. *F1-score* memberikan gambaran umum tentang keseimbangan antara *precision* dan *recall*. Selain itu, evaluasi juga dilakukan menggunakan *Area Under the Curve* (AUC) untuk mengukur kemampuan model dalam membedakan kelas positif dan negatif pada data yang tidak seimbang (Yang & Ying, 2022).

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (1)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

$$\text{F1 - score} = 2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (4)$$

**Keterangan:**

TP = *True Positive*

TN = *True Negative*

FN = *False Positive*

FP = *False Negatif*

## HASIL DAN PEMBAHASAN

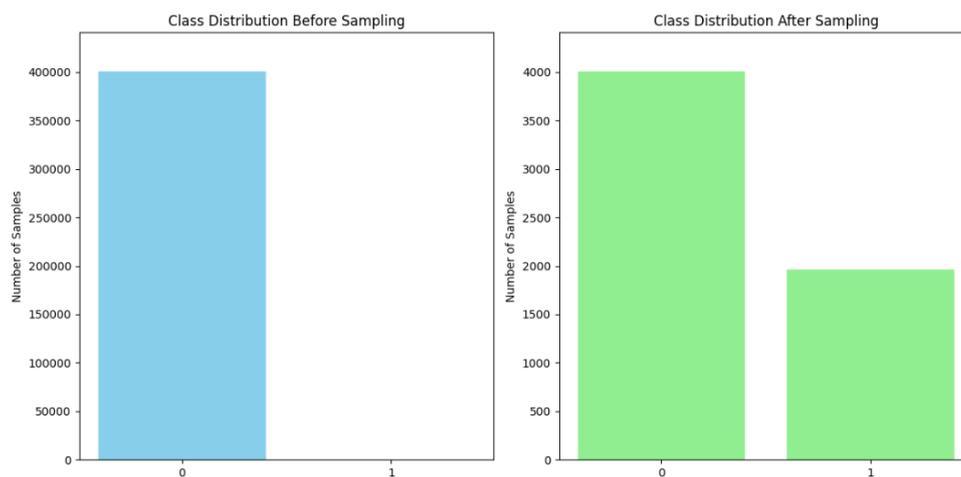
### Hasil

Dataset ISIC 2024 yang digunakan dalam penelitian ini terdiri dari 401.059 citra serta 49 fitur dalam data tabular yang diperoleh dari 3D *Total Body Photography*. Dataset ini mencakup berbagai karakteristik lesi kulit, seperti ukuran, warna, bentuk, serta parameter klinis dan anatomi. Beberapa fitur utama dalam dataset ini meliputi target, usia, jenis kelamin pasien, lokasi lesi pada tubuh, serta diameter lesi. Selain itu, dataset ini juga mencakup metrik tambahan seperti indeks mitosis, dan ketebalan *melanoma* untuk mendukung analisis lebih lanjut dalam deteksi kanker kulit. Kemudian, pada Tabel 1 ditampilkan distribusi kelas pada fitur target, yang mengelompokkan lesi ke dalam kategori *benign* dan *malignant*. Distribusi ini memberikan gambaran tentang terjadinya ketidakseimbangan kelas dalam dataset.

**Tabel 1.** Pembagian jumlah fitur target

<i>Class</i>	<i>Jumlah</i>	<i>Keterangan</i>
0	400.666	<i>Benign</i>
1	393	<i>Malignant</i>

Hasil eksperimen pada tahap *preprocessing* menunjukkan adanya missing value, terutama pada fitur *age\_approx*. Untuk mengatasi hal ini, dilakukan imputasi dengan menggantikan nilai yang hilang menggunakan *median*, sehingga distribusi data tetap seimbang dan representatif. Setelah proses *data cleaning* selesai, tahap selanjutnya adalah *normalisasi* fitur numerik guna memastikan bahwa semua fitur berada dalam skala yang seragam. Normalisasi ini berperan penting dalam meningkatkan stabilitas model serta membantu dalam mendeteksi pola data secara lebih akurat. Setelah normalisasi, fitur kategorikal kemudian dikonversi ke dalam format numerik menggunakan *one-hot encoding*. Teknik ini diterapkan untuk menghindari skala numerik yang tidak sesuai serta memastikan bahwa setiap kategori direpresentasikan secara setara dalam model. Dengan *one-hot encoding*, setiap kategori dalam fitur dikodekan sebagai *vektor biner*, memungkinkan model memahami hubungan antar kategori tanpa menimbulkan bias. Kemudian proses penyeimbangan data menggunakan metode *undersampling* dan *oversampling* menghasilkan seperti pada gambar 1.



**Gambar 1.** Distribusi kelas sebelum dan sesudah penyeimbangan data

Gambar 1 menunjukkan distribusi fitur target sebelum dan sesudah penyeimbangan data. Awalnya, dataset mengalami ketimpangan kelas yang signifikan, dengan dominasi kelas 0. Untuk mengatasi hal ini, kami menerapkan *undersampling* menggunakan *RandomUnderSampler* dalam *pipeline VotingClassifier* dengan rasio 1% untuk mengurangi dominasi kelas mayoritas. Selain itu, *oversampling* dilakukan menggunakan *pandas*, di mana class 1 diperbanyak hingga 5 kali lipat guna meningkatkan representasi tanpa menyebabkan *overfitting*. Setelah proses ini, distribusi data menjadi lebih seimbang, dengan 4.007 sampel untuk class 0 dan 1.965 sampel untuk class 1. Hasil ini menunjukkan penggunaan kedua teknik tersebut memberikan peran signifikan untuk mengatasi keseimbangan class.

Setelah data berhasil diseimbangkan selanjutnya augmentasi pada citra dengan menggunakan *KerasCV* dilakukan menggunakan teknik *random cutout* (20% area), *random flip* (horizontal dan vertikal), serta *random apply* dengan probabilitas 50%. Setelah proses augmentasi, data dibagi menjadi dua bagian dengan rasio 80% untuk data train dan 20% untuk data valid, menghasilkan 4.777 sampel untuk training dan 1.195 sampel untuk validasi.

Pada tahap *modelling*, digunakan arsitektur *multi-input* yang menggabungkan *EfficientNetV2-B2* sebagai ekstraksi fitur citra dan *LightGBM* sebagai *estimator* prediksi data tabular. Model ini menggunakan konfigurasi *pretrained ImageNet* untuk memanfaatkan bobot yang telah dipelajari sebelumnya dari dataset skala besar, sehingga dapat mempercepat konvergensi dan meningkatkan akurasi prediksi. Arsitektur model CNN yang digunakan mencakup beberapa lapisan utama. *Backbone* *EfficientNetV2-B2* mengekstrak fitur dari citra input dengan keluaran berukuran  $4 \times 4 \times 1408$ . Fitur ini kemudian diproses melalui *Global*

*Average Pooling* sebelum diteruskan ke lapisan *Dropout* dengan nilai 0,3 untuk mengurangi risiko *overfitting*. Sementara itu, *output* dari LightGBM, yang berupa probabilitas prediksi, digabungkan dengan fitur hasil ekstraksi CNN pada lapisan *Concatenate* sebelum akhirnya masuk ke lapisan *Dense* sebagai *output* akhir.



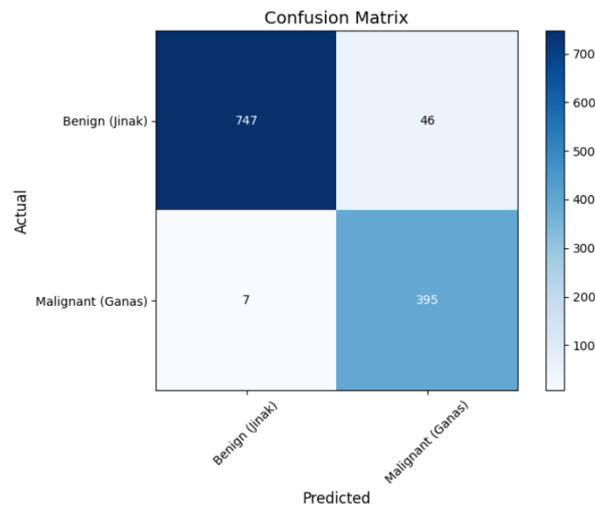
**Gambar 2.** Parameter arsitektur model

Gambar 2 menunjukkan ringkasan parameter arsitektur model yang digunakan. Model ini dilatih menggunakan *optimizer Adam* dengan *batch size* 16, *learning rate* 0,00001, dan 8 *epoch*. Adam dipilih karena kemampuannya menyesuaikan *learning rate* secara adaptif, sehingga konvergensi lebih stabil. *Learning rate* yang kecil mencegah osilasi, sementara *batch size* 16 menjaga keseimbangan antara stabilitas pelatihan dan efisiensi memori. Jumlah *epoch* ditetapkan 8 karena model telah mencapai *konvergensi*, untuk menghindari risiko *overfitting*.

Tabel 2 menunjukkan hasil *classification report* dari pelatihan model. Model menunjukkan akurasi sebesar 0,96 (96%), yang menandakan bahwa sebagian besar prediksi model sesuai dengan kelas yang benar. Hasil *precision* untuk kelas *benign* sangat tinggi 0,99, menandakan bahwa model memiliki akurasi yang luar biasa dalam mengidentifikasi lesi *benign*. Namun, untuk kelas *malignant*, *precision* sedikit lebih rendah 0,90, yang menunjukkan bahwa model terkadang salah mengklasifikasikan lesi *malignant* sebagai *benign*. *Recall* menunjukkan bahwa model cukup sensitif terhadap lesi *malignant* 0,98, yang berarti sebagian besar lesi kanker berhasil dideteksi. *F1-score* untuk kedua kelas juga menunjukkan nilai yang sangat baik, yaitu 0,94 untuk *malignant* dan 0,97 untuk *benign*, mencerminkan keseimbangan yang baik antara *precision* dan *recall*.

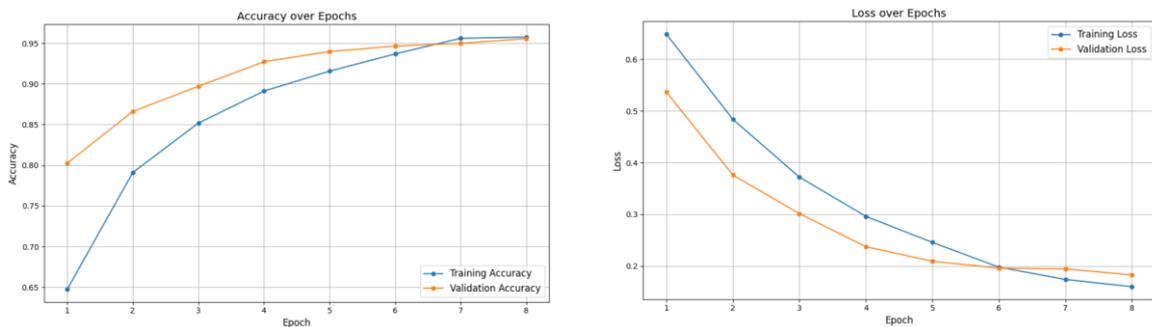
**Tabel 2.** Hasil *classification report*

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
<i>Benign</i> (0)	0,99	0,94	0,97	793
<i>Melignant</i> (1)	0,90	0,98	0,94	402
<i>Accuracy</i>			0,96	1195
<i>Micro avg</i>	0,94	0,96	0,95	1195
<i>Weighted avg</i>	0,96	0,96	0,96	1195

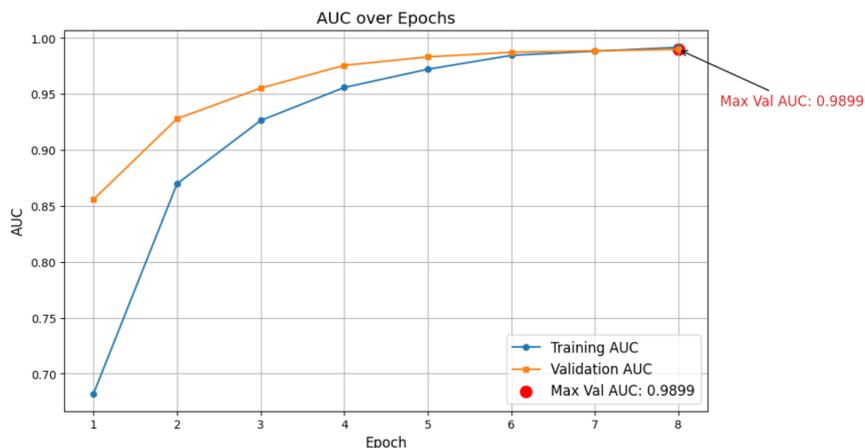


**Gambar 3.** Hasil *confusion matrix*

Hasil *confusion matrix* yang di tampilkan pada gambar 3 dapat dilihat bahwa sebagian besar kesalahan prediksi terjadi pada kelas *benign*, dengan 46 lesi *benign* diklasifikasikan sebagai *malignant*. Kesalahan prediksi yang terjadi pada kelas *benign* lebih sering terjadi dibandingkan dengan kelas *malignant*. Meskipun *recall* untuk *malignant* cukup tinggi, model masih memiliki kelemahan dalam mengidentifikasi lesi *benign* yang memiliki fitur serupa dengan *malignant*. Pola kesalahan ini bisa disebabkan oleh kesulitan model dalam membedakan lesi *benign* dengan beberapa karakteristik yang mirip dengan lesi kanker kulit. Misalnya, beberapa lesi *benign* dengan ukuran besar atau perubahan warna yang tidak biasa mungkin disalahartikan sebagai *malignant*.



**Gambar 4.** Hasil *accuracy* dan *loss* per *epoch*



**Gambar 5.** Hasil *area under curve*

Gambar 4 menunjukkan model mengalami peningkatan akurasi secara stabil dan penurunan *loss* secara konsisten selama pelatihan. Hal ini menunjukkan bahwa model dapat belajar dari data dengan baik tanpa adanya masalah besar dalam hal *konvergensi*. *Loss* yang menurun secara konsisten menunjukkan bahwa model semakin akurat dalam memprediksi label yang benar seiring berjalannya waktu. Berdasarkan hasil ini model tidak ada indikasi *overfitting* atau *underfitting* yang signifikan, karena akurasi meningkat stabil dan *loss* menurun konsisten, yang menunjukkan bahwa model tidak menghafal data atau tidak kurang belajar dari data.

Hasil evaluasi menggunakan AUC yang ditampilkan pada gambar 5 menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara kelas *benign* dan *malignant*. Nilai AUC yang diperoleh mencapai 0,9899, menunjukkan bahwa model dapat membedakan lesi dari dua kelas dengan sangat baik. Hasil penelitian ini menunjukkan bahwa model yang diusulkan tidak hanya efektif dalam mengklasifikasikan lesi kanker kulit, tetapi juga sangat *robust* dalam menangani masalah ketidakseimbangan kelas. Selain itu, hasil ini menunjukkan bahwa model lebih efisien dalam penggunaan sumber daya komputasi dibandingkan dengan arsitektur CNN konvensional, sehingga dapat mengurangi beban komputasi tanpa mengorbankan akurasi.

## Pembahasan

Penelitian ini mengimplementasikan model *multi-input* yang menggabungkan arsitektur EfficientNetV2-B2 untuk ekstraksi fitur citra dan LightGBM untuk *estimator* prediksi dari data tabular. Hasil eksperimen menunjukkan bahwa model *multi-input* ini memiliki akurasi 96%. Informasi dari data tabular seperti usia, jenis kelamin pasien, lokasi lesi pada tubuh, serta diameter lesi dapat memberikan wawasan tambahan pada model terutama untuk lesi dengan citra yang kurang jelas. Ini merupakan salah satu keunggulan dibandingkan dengan hanya mengandalkan citra saja, yang dapat memiliki keterbatasan dalam mendeteksi kasus-kasus tertentu, seperti *melanoma* dengan gejala yang kurang jelas secara visual.

Ketidakseimbangan kelas pada dataset ini menjadi tantangan yang signifikan, dengan 400.666 sampel lesi *benign* dan hanya 393 sampel lesi *malignant*. Dalam penelitian ini, kami menggabungkan dua teknik penyeimbangan data yaitu *undersampling* mengurangi jumlah sampel pada kelas *benign* untuk menghindari dominasi kelas mayoritas, sementara *oversampling* meningkatkan jumlah sampel pada kelas *malignant* untuk memperbaiki representasi. Pendekatan ini lebih efektif dikarenakan dapat secara bersamaan mengatasi ketidakseimbangan dua kelas secara bersamaan. Dengan teknik ini, distribusi data menjadi lebih seimbang, yang berkontribusi pada peningkatan akurasi, *precision*, dan *recall* untuk kelas *malignant*.

Model yang diusulkan dalam penelitian ini memiliki potensi besar dalam membantu diagnosis kanker kulit secara cepat. Dengan kemampuan dalam menganalisis citra dermoskopi serta data klinikal pasien, model ini dapat digunakan sebagai alat bantu bagi dokter kulit dalam mengidentifikasi dan mengklasifikasikan lesi kulit secara lebih cepat dan akurat tanpa menggunakan prosedur biopsi. Namun, ada beberapa tantangan dalam penerapannya di dunia nyata. Pertama, validasi eksternal dalam lingkungan medis sangat penting untuk memastikan model dapat bekerja dengan baik pada data yang lebih beragam dan lebih besar. Selain itu, meskipun teknik augmentasi dan penyeimbangan data membantu, *overfitting* masih menjadi tantangan potensial yang harus diperhatikan, terutama jika model terlalu mengandalkan pola-pola tertentu dalam data pelatihan yang tidak berlaku di dunia nyata.

Penelitian sebelumnya yang menggunakan CNN konvensional dengan hanya menggunakan teknik augmentasi berupa *grayscale* dan dataset yang sudah cukup seimbang memperoleh akurasi 94% (Claret et al., 2024). Sementara itu, penelitian kami tetap menggunakan gambar warna penuh untuk memanfaatkan informasi lebih banyak, kami

meyakini bahwa meskipun teknik *grayscale* berguna untuk mengurangi noise, penggunaan citra berwarna memberikan hasil yang lebih baik dalam mendeteksi kanker kulit karena informasi tambahan yang diberikan oleh warna.

Penting untuk mempertimbangkan keberagaman jenis lesi dalam pengumpulan data lebih lanjut. Aspek yang perlu diperhatikan adalah resolusi gambar, kontras, serta pencahayaan, yang dapat mempengaruhi kemampuan model untuk mendeteksi fitur penting dalam citra kulit. Selain itu, ketika model ini diimplementasikan dalam klinis yang lebih luas, penting untuk terus memantau kemungkinan terjadinya *overfitting*, terutama jika model terlalu bergantung pada pola data tertentu. Oleh karena itu, peran dari teknik augmentasi dan sampling yang baik menjadi sangat vital dalam menjaga generalisasi model agar tetap akurat di berbagai situasi klinis yang bervariasi.

## SIMPULAN

Penelitian ini berhasil mengembangkan model *multi-input* yang menggabungkan EfficientNetV2-B2 untuk ekstraksi fitur citra dan LightGBM untuk *estimator* prediksi data tabular, yang secara signifikan meningkatkan akurasi deteksi kanker kulit dengan mencapai akurasi 96%. Model ini tidak hanya berhasil meningkatkan akurasi, tetapi juga efektif dalam menangani masalah ketidakseimbangan kelas melalui penerapan teknik *undersampling* dan *oversampling*, serta memperkaya informasi dengan menggabungkan data citra dan tabular. Selain itu, model ini menunjukkan efisiensi komputasi yang lebih tinggi dibandingkan dengan model CNN konvensional, memungkinkan proses pelatihan yang lebih cepat dan penggunaan sumber daya yang lebih efisien. Kontribusi utama penelitian ini adalah penggabungan dua jenis data (citra dan tabular) yang memberikan gambaran lebih lengkap untuk deteksi kanker kulit, serta penerapan teknik penyeimbangan yang efektif untuk meningkatkan kinerja model dalam kondisi data yang tidak seimbang.

## REFERENSI

- Adzhani, A., Darusman, F., & Aryani, R. (2022). Kajian Efek Radiasi Ultraviolet terhadap Kulit. *Bandung Conference Series: Pharmacy*, 2(2), 106–112. <https://doi.org/10.29313/bcsp.v2i2.3551>
- Akhter, A., Hasan, K. F., & Moni, M. A. (2022). Machine Learning-based Lung and Colon Cancer Detection using Deep Feature Extraction and Ensemble Learning. *Expert System with Applications*, 205, 0957-4174. <https://doi.org/10.1016/j.eswa.2022.117695>
- Akinrinade, O., & Du, C. (2025). Skin cancer detection using deep machine learning techniques. *Intelligence-Based Medicine*, 11, 100191. <https://doi.org/10.1016/j.ibmed.2024.100191>
- Bintang, Y. K., & Imaduddin, H. (2024). Pengembangan Model Deep Learning Untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning. *Jurnal Ilmiah Penelitian dan Pembelajaran Informatika* 9(3), 1442–1455. <https://doi.org/10.29100/jipi.v9i3.5588>
- Claret, S. A., Dharmian, J. P., & Manokar, A. M. (2024). Artificial intelligence-driven enhanced skin cancer diagnosis: leveraging convolutional neural networks with discrete wavelet transformation. *Egyptian Journal of Medical Human Genetics*, 25(1), 1-12. <https://doi.org/10.1186/s43042-024-00522-5>
- Faruk, M., & Nafi'iyah, N. (2020). Klasifikasi Kanker Kulit Berdasarkan Fitur Tekstur, Fitur Warna Citra Menggunakan SVM dan KNN. *Telematika*, 13(2), 100–109. <https://doi.org/10.35671/telematika.v13i2>
- Hameed, M., Zameer, A., & Zahoor Raja, M. A. (2024). A Comprehensive Systematic Review: Advancements in Skin Cancer Classification and Segmentation Using the ISIC Dataset. *CMES - Computer Modeling in Engineering and Sciences*, 140(3), 2131–2164. <https://doi.org/10.32604/cmescs.2024.050124>

- Hasan, M. R., Fatemi, M. I., Monirujjaman Khan, M., Kaur, M., & Zaguia, A. (2021). Comparative analysis of skin cancer (benign vs. malignant) detection using convolutional neural networks. *Journal of Healthcare Engineering*, 2021(1), 5895156. <https://doi.org/10.1155/2021/5895156>
- Huang, M. L., & Liao, Y. C. (2023). Stacking Ensemble and ECA-EfficientNetV2 Convolutional Neural Networks on Classification of Multiple Chest Diseases Including COVID-19. *Academic Radiology*, 30(9), 1915–1935. <https://doi.org/10.1016/j.acra.2022.11.027>
- Ichwan, M., & Hadi, I. S. (2023). Kinerja Model EfficientNetV2M dalam Klasifikasi Citra Tutupan dan Penggunaan Lahan. *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, 8(2), 203-216.
- Ieracitano, C., Morabito, F. C., Hussain, A., Suffian, M., & Mammone, N. (2025). TIXAI: A Trustworthiness Index for eXplainable AI in skin lesions classification. *Neurocomputing*, 630, 129701. <https://doi.org/10.1016/j.neucom.2025.129701>
- Kingsley, J. (2023). *Skin Biopsy: Types, Procedure, and What to Expect*. Retrieved Maret 18, 2025, from The Kingsley Clinic website: <https://thekingsleyclinic.com/resources/skin-biopsy-types-procedure-and-what-to-expect/>
- Hakim, L., Sari, Z., & Handhajani, H. (2021). Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 379–385. <https://doi.org/10.29207/resti.v5i2.3001>
- Nisa, K., Informatika, P. S., & Bangsa, U. H. (2024). Klasifikasi Penyakit Gangguan Mental dengan Algoritma LightGBM. *JURASIK (Jurnal Riset Sistem Informasi dan Teknik Informatika)*, 9(2), 1086–1094.
- Oktora, M. Z., Haiga, Y., & Liana, N. (2023). Peningkatan Pengetahuan Masyarakat terhadap Pengaruh Paparan Sinar Matahari yang dapat Menyebabkan Kanker Kulit. *Jurnal Pengabdian Masyarakat Kesehatan (JURABDIKES)*, 1(2), 28–31. <https://doi.org/10.56260/jurabdikes.v1i2.105>
- Pratama, A. B., Herowati, R., & Ansory, H. M. (2021). Studi Docking Molekuler Senyawa Dalam Minyak Atsiri Pala (*Myristica fragrans* H.) Dan Senyawa Turunan Miristisin Terhadap Target Terapi Kanker Kulit. *Majalah Farmaseutik*, 17(2), 233-242. <https://doi.org/10.22146/farmaseutik.v17i2.59297>
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F. (2021). Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209–249. <https://doi.org/10.3322/caac.21660>
- Tan, M., & Le, Q. V. (2021). EfficientNetV2: Smaller Models and Faster Training. *Proceedings of Machine Learning Research*, 139, 10096–10106.
- Tarisa, R. E. D., Rustam, R., & Elmatris, E. (2022). Hubungan Jenis Pekerjaan dengan Kanker Kulit di RSUP Dr. M. Djamil Padang Tahun 2015 - 2020. *Jurnal Ilmu Kesehatan Indonesia*, 3(1), 67–73. <https://doi.org/10.25077/jikesi.v3i1.739>
- Yang, T., & Ying, Y. (2022). AUC Maximization in the Era of Big Data and AI : A Survey. *Association for Computing Machinery*, 55(8), 0360-0300. <https://doi.org/10.1145/3554729>
- Yogiswara, I. G. A. I., Saputra, H., & Ekawati, N. P. (2021). Karakteristik pasien kanker kulit non-melanoma di RSUP Sanglah pada periode tahun 2014 - 2018. *Intisari Sains Medis*, 12(2), 691–694. <https://doi.org/10.15562/ism.v12i2.1080>