Jurnal Ilmiah Teknik Informatika dan Komunikasi
Volume 5. Nomor. 2 Juli 2025
E-ISSN: 2827-7945 ; P-ISSN: 2827-8127, Hal 94-113
DOI: https://doi.org/10.55606/juitik.v5i2.1026
Available online at: https://journal.sinov.id/index.php/juitik

Implementasi Arsitektur CNN DenseNet-121 untuk Identifikasi Autoimun Kulit dengan Augmentasi Data

Annisa Lusyani Zahra[1*],Amalia Anjani Arifiyanti[2], Tri Luhur Indayanti Sugata[3]
[1,2,3]Sistem Informasi, Universitas Pembangunan Nasional Veteran Jawa Timur, Indonesia

Alamat: Jalan Rungkut Madya Surabaya, Indonesia
Korespondensi penulis: 20082010153@student.upnjatim.ac.id[*]

Abstract. *Autoimmune skin diseases are conditions in which the immune system mistakenly attacks healthy skin tissue, causing inflammation, tissue damage, and changes in skin color. The similarity of symptoms among various autoimmune skin diseases, such as psoriasis, lichen planus, vitiligo, hidradenitis suppurativa, and dermatomyositis, presents a challenge for accurate and timely diagnosis. This study was conducted to support the diagnostic process by utilizing deep learning technology, specifically the Convolutional Neural Network (CNN) method with the DenseNet121 architecture. Data augmentation techniques were also applied in this study to increase dataset variation, allowing for a performance comparison between the original dataset and the augmented dataset. The results show that the CNN model with the DenseNet121 architecture, configured with a batch size of 32 and 60 epochs on the augmented dataset, achieved a high accuracy rate of 92.43%. The model was then implemented into a web-based application and integrated using the Flask framework.*

Keywords: *Autoimmune Skin Diseases; CNN; Data Augmentation; DenseNet121*

Abstrak. Autoimun kulit merupakan penyakit dengan kondisi sistem imun menyerang jaringan kulit yang sehat, menimbulkan peradangan, kerusakan jaringan, dan perubahan warna kulit. Banyaknya kesamaan gejala pada penyakit autoimun kulit, seperti psoriasis, lichen planus, vitiligo, hidradenitis suppurativa, dan dermatomiositis, menjadi tantangan dalam proses diagnosis secara cepat dan akurat. Dilakukannya penelitian ini untuk mendukung proses diagnosis tersebut, penelitian ini memanfaatkan teknologi *deep learning* menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur DenseNet121. Teknik Augmentasi juga diterapkan pada penelitian ini untuk memperbanyak variasi dataset, sehingga memungkinkan perbandingan performa model antara *original dataset* dan *augmented dataset*. Hasil penelitian menunjukkan bahwa model CNN dengan arsitektur DenseNet121, konfigurasi *batch size* 32 dan *epoch* 60 pada *augmented dataset*, mampu mencapai tingkat akurasi sebesar 92,43%. Model tersebut selanjutnya diimplementasikan ke dalam aplikasi berbasis *web* dan diintegrasikan menggunakan *framework Flask*.

Kata kunci: Augmentasi Data; Autoimun Kulit; CNN; DenseNet121

1. LATAR BELAKANG

Autoimun merupakan penyakit yang memiliki suatu kondisi di mana sistem imun tubuh mengalami gangguan, sehingga sel-sel imun dan antibodi yang seharusnya melindungi tubuh dari infeksi bakteri dan virus, sebaliknya menyerang jaringan tubuh sendiri. Dalam kondisi normal, sistem imun berfungsi untuk mengenali dan melawan patogen asing. Namun, pada kasus autoimun, sistem imun keliru mengenali jaringan tubuh sebagai ancaman yang perlu dihancurkan (Albarbar & Aga, 2024).

Autoimun dapat mempengaruhi hampir seluruh bagian tubuh, salah satunya adalah kulit. Autoimun pada kulit dapat menyebabkan peradangan, kerusakan, dan perubahan kondisi kulit akibat kelainan pada sistem imun. Beberapa contoh penyakit autoimun kulit diantaranya,

Received: April 16, 2025; Revised: April 30, 2025; Accepted: Mei 16, 2025; Online Available: Mei 18, 2025

psoriasis yang ditandai dengan bercak merah bersisik (Raharja et al., 2021), vitiligo dengan hilangnya pigmen kulit (Bergqvist & Ezzedine, 2020), lichen planus yang menyebabkan gatal disertai perubahan warna ungu (Boch et al., 2021), hidradenitis suppurativa yang ditandai dengan benjolan nyeri (Ingram, 2020), serta dermatomyositis yang menimbulkan ruam akibat peradangan pada otot dan kulit (Tanboon et al., 2022).

Penyakit-penyakit tersebut sering kali menunjukkan gejala yang mirip, sehingga diperlukan diagnosis yang akurat dan deteksi dini untuk mencegah komplikasi lebih lanjut serta memastikan penanganan yang tepat. Kesulitan dalam mengidentifikasi gejala-gejala ini, baik oleh masyarakat umum maupun tenaga medis, menunjukkan perlunya dukungan teknologi dalam proses diagnosis (Albarbar & Aga, 2024).

Seiring perkembangan teknologi yang pesat, kecerdasan buatan (*Artificial Intelligence*/AI) dan *machine learning* telah banyak diterapkan di berbagai bidang, termasuk kesehatan. Dengan memanfaatkan *Artificial Intelligence* (AI) dan *machine learning*, teknologi ini mampu mengolah, menganalisis, dan memberikan solusi untuk permasalahan, sehingga penanganan dapat dilakukan secara lebih efisien (Janiesch et al., 2021). Penelitian yang dilakukan oleh Zhong et al. (2020), menerapkan deep learning untuk dapat menganalisis citra medis sehingga dapat mendeteksi penyakit kanker.

Deep learning merupakan bagian dari *machine learning* dan komponen penting dalam pengembangan sistem kecerdasan buatan (AI). *Deep learning* memanfaatkan jaringan saraf tiruan (*neural network*) yang terdiri dari *input layer, hidden layer,* dan *output layer* untuk memproses dan menganalisis data yang kompleks (Janiesch et al., 2021). *Deep learning* ini terinspirasi oleh struktur otak manusia, sehingga menjadikannya sangat efektif dalam mengolah data yang tidak terstruktur dengan baik, seperti yang ditemukan dalam penelitian ini, yaitu berupa data gambar (Taye, 2023).

Salah satu metode *deep learning* yang banyak digunakan adalah *Convolutional Neural Networks* (CNN), metode ini mampu mengenali dan mengklasifikasikan fitur-fitur dalam gambar melalui beberapa layer diantaranya *input image, convolutional layer, pooling layer, activation function, fully connected layer,* dan *output layer*. Struktur komponen-komponen dalam CNN ini menjadikannya pilihan yang baik untuk mengklasifikasikan gambar (Bhatt et al., 2021).

DenseNet121 merupakan arsitektur *Convolutional Neural Network* (CNN) yang memiliki karakteristik berupa keterhubungan langsung antara setiap lapisannya. Keterhubungan ini memungkinkan penyebaran informasi yang lebih kaya, meningkatkan

kemampuan dalam mengenali fitur, serta mengurangi potensi hilangnya informasi selama proses penyebaran informasi melalui *neural network* (Hasan et al., 2021).

Augmentasi data merupakan teknik yang digunakan untuk menghasilkan akurasi yang tinggi pada model, terutama ketika jumlah data pelatihan terbatas (Yang et al., 2023a). Teknik ini melibatkan berbagai transformasi, di antaranya rotasi, pergeseran, *shear*, *zoom*, *flipping*, dan lainnya, yang bertujuan untuk menghasilkan variasi dalam data. Dengan penerapan transformasi ini, data pelatihan akan memiliki keberagaman yang lebih luas, mendukung pembangunan model yang lebih kuat. Penerapan teknik augmentasi ini terbukti efektif dalam menghasilkan akurasi yang tinggi, sebagaimana dibuktikan oleh penelitian yang dilakukan oleh Putri et al. (2023), menggunakan augmentasi data untuk meningkatkan jumlah citra dari semula 115 citra untuk 3 kelas menjadi total 1.035 citra.

Berdasarkan pemaparan tersebut, penelitian ini dilakukan untuk mengidentifikasi penyakit kulit autoimun menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur DenseNet121 serta menerapkan teknik augmentasi data. Tujuan penelitian ini adalah membangun model klasifikasi citra medis yang dapat membantu proses identifikasi penyakit secara cepat dan akurat. Diharapkan hasil penelitian ini dapat memberikan kontribusi kepada masyarakat maupun dokter kulit dalam melakukan diagnosis sehingga memungkinkan penanganan yang lebih efisien dan tepat waktu.

2. KAJIAN TEORITIS

Autoimun Kulit

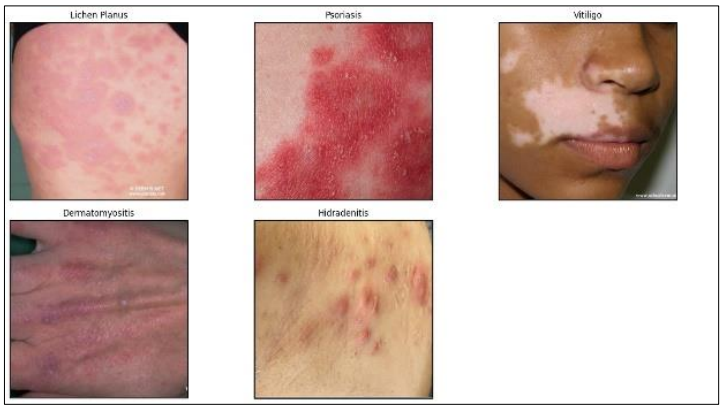

Gambar 1. Autoimun Kulit

Autoimun kulit merupakan kondisi di mana sistem imun menyerang jaringan kulit, yang mengakibatkan peradangan, kerusakan, dan perubahan pada kondisi kulit. Pada Gambar 1 menyajikan ilustrasi penyakit autoimun kulit, agar lebih jelas berikut ini adalah uraian dari beberapa penyakit autoimun kulit yang umum antara lain:

a. Lichen planus adalah kondisi kulit yang ditandai dengan peradangan, yang dapat mempengaruhi kulit, rambut, kuku, dan membran mukosa (Boch et al., 2021).
b. Psoriasis adalah kondisi kulit yang ditandai dengan munculnya bercak merah yang bersisik dan kering, yang disebabkan oleh pertumbuhan sel kulit yang cepat (Raharja et al., 2021).
c. Vitiligo adalah kondisi kulit yang ditandai dengan hilangnya pigmen kulit, yang disebabkan oleh kehancuran sel melanosit, sehingga mengganggu produksi melanin pada area kulit yang terpengaruh (Bergqvist & Ezzedine, 2020).
d. Dermatomyositis adalah kondisi kulit yang ditandai dengan peradangan pada otot dan lesi kulit, yang menyebabkan ruam berwarna ungu atau merah di area kulit tertentu (Tanboon et al., 2022).
e. Hidradenitis suppurativa adalah kondisi kulit yang ditandai dengan pembentukan abses yang menyakitkan dan dapat pecah, yang biasanya muncul di area lipatan tubuh (Ingram, 2020).

Deep Learning

Deep learning merupakan subbidang dari machine learning, terdiri dari banyak lapisan yang dapat mempelajari representasi data yang kompleks. Setiap lapisan berisi unit-unit yang disebut neuron buatan, yang memungkinkan model untuk menangkap pola-pola yang lebih kompleks dalam data. Dengan kemampuan ini, *deep learning* lebih unggul dibandingkan algoritme *machine learning* sederhana lainnya, karena dapat menangani dan menganalisis data dalam pengolahan citra, pengenalan suara, dan analisis video secara lebih efektif (Taye, 2023).

Convolutional Neural Network (CNN)

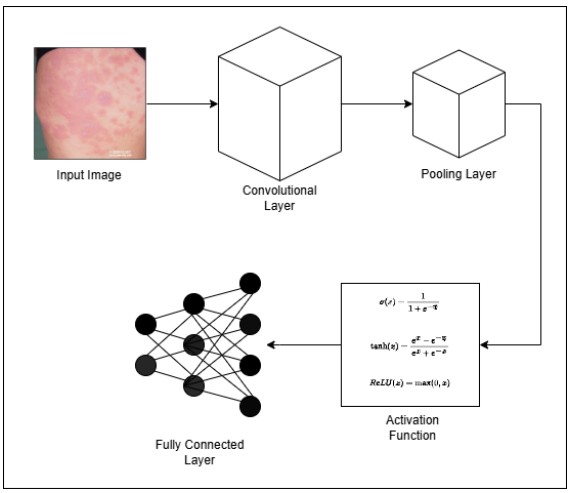

Gambar 2. Arsitektur CNN

Convolutional Neural Network (CNN) dapat dilihat pada Gambar 2, merupakan metode dalam bidang *deep learning* yang banyak diterapkan dalam berbagai tugas pengolahan data, terutama dalam pengolahan citra. CNN memiliki empat lapisan utama, yaitu *convolutional layer, pooling layer, activation function*, dan *fully connected layer* (Bhatt et al., 2021). Berikut ini adalah penjelasan untuk setiap lapisan tersebut:

a. *Convolutional layer* adalah lapisan utama dalam jaringan syaraf konvolusional (CNN) yang berfungsi untuk mengekstraksi fitur penting dari *data input*, terutama gambar. Lapisan ini menggunakan *filter* atau kernel yang berupa matriks kecil yang bergerak (konvolusi) di atas gambar untuk mendeteksi pola-pola seperti tepi, sudut, atau tekstur. Setiap filter akan menghasilkan *feature map* yang menyajikan representasi fitur tertentu pada gambar. Proses ini memungkinkan model untuk memahami karakteristik gambar secara hierarkis, dimulai dari fitur-fitur dasar hingga fitur yang lebih kompleks.
b. *Pooling layer* bertujuan untuk mengurangi dimensi data, yang mengurangi kebutuhan komputasi dan mempercepat pemrosesan. Selain itu, *pooling layer* membantu mengekstraksi karakteristik penting yang bersifat posisi dan rotasi invariansi, memungkinkan model mengenali fitur yang sama meskipun terjadi perubahan posisi atau rotasi. Proses ini juga berkontribusi pada efisiensi pelatihan model. Terdapat dua jenis teknik pooling yang umum digunakan, yaitu *maximum pooling* dan *average pooling*, yang keduanya bertujuan mengurangi ukuran data, namun dengan pendekatan yang berbeda: *maximum pooling* memilih nilai maksimum dalam area tertentu, sementara *average pooling* menghitung rata-rata nilai dalam area tersebut.
c. Fungsi aktivasi memiliki peran yang sangat penting dalam jaringan saraf konvolusional (CNN), terutama pada lapisan ekstraksi fitur. Fungsi aktivasi ini mengubah nilai output akhir dari jaringan saraf, dengan salah satu yang paling umum digunakan adalah ReLU (*Rectified Linear Unit*), yang mengubah nilai menjadi nol jika negatif dan mempertahankan nilai positif jika lebih besar dari nol. Terdapat dua kategori utama fungsi aktivasi, yaitu linear dan non-linear. Perbedaan utama antara keduanya terletak pada kemampuannya dalam memproses data yang kompleks. Fungsi aktivasi non-linear lebih unggul dibandingkan linear karena kemampuannya untuk memodelkan hubungan yang lebih rumit dalam data, sehingga lebih sering diterapkan dalam tugas-tugas yang melibatkan data kompleks seperti citra, video, dan audio.
d. *Fully connected layer* merupakan lapisan dalam jaringan saraf yang memiliki sifat *feed-forward*, di mana setiap neuron pada lapisan ini terhubung dengan semua neuron pada

lapisan sebelumnya. Pada lapisan ini, dilakukan pengolahan lebih lanjut terhadap data untuk menghasilkan prediksi, setelah menerima *output* dari lapisan sebelumnya yang telah melalui proses *flattening*.

DenseNet121

DenseNet121 merupakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang untuk tugas pengenalan objek visual. Sesuai dengan namanya, "Dense" di mana setiap lapisan pada DenseNet121 tidak hanya terhubung ke lapisan berikutnya, tetapi juga ke semua lapisan sebelumnya. Mekanisme ini memungkinkan informasi dapat tersalurkan secara lebih efektif di seluruh jaringan, sehingga meningkatkan kemampuan dalam mengenali fitur serta mengurangi kehilangan informasi selama proses penyebaran informasi melalui *neural network* (Hasan et al., 2021).

Augmentation Data

Augmentasi data adalah teknik yang digunakan untuk meningkatkan performa model dan mencegah *overfitting* dengan cara memperbanyak variasi data (Yang et al., 2023b). Teknik ini dilakukan dengan menerapkan berbagai transformasi pada data citra, seperti rotasi, pergeseran, *shear, zoom, flipping*, dan lainnya. Dengan demikian, augmentasi data menghasilkan set data sintetis yang dapat memperluas keragaman data pelatihan (Yang et al., 2023a).

Confusion Matrix

Confusion matrix merupakan alat utama dalam evaluasi performa model yang telah dibangun (Munandar et al., 2023). Matriks ini digunakan untuk mengukur seberapa efektif model dalam mengklasifikasikan data ke dalam kategori atau kelas yang benar, dengan membandingkan hasil prediksi model terhadap data aktual (Markoulidakis et al., 2021). Tabel 1 ini adalah representasi dari *confusion matrix*:

Tabel 1. *Confusion Matrix*

		Kelas Prediksi	
		Kelas Positif	**Kelas Negatif**
Kelas Aktual	**Kelas Positif**	TP	FP
	Kelas Negatif	FN	TN

Dari tabel representasi *confusion matrix* tersebut, dapat dihitung beberapa metrik untuk mengevaluasi performa model, di antaranya akurasi, *recall*, presisi, dan F1-*score*. Berikut adalah rumus-rumus untuk menghitung metrik-metrik tersebut:

a. Akurasi digunakan untuk mengukur model membuat prediksi yang benar, baik untuk kelas positif ataupun negatif.

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

b. *Recall* digunakan untuk mengukur model seberapa baik untuk menemukan seluruh data yang termasuk ke dalam kelas positif.

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

c. Presisi digunakan untuk mengukur apakah suatu model akurat dalam memprediksi kelas positif.

$$Presisi = \frac{TP}{TP + FP}$$

d. F1-*score* digunakan untuk mencari rata-rata harmonik dari presisi dan *recall* terutama ketika mempertimbangkan ketidakseimbangan dataset.

$$F1\ Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$$

3. METODE PENELITIAN

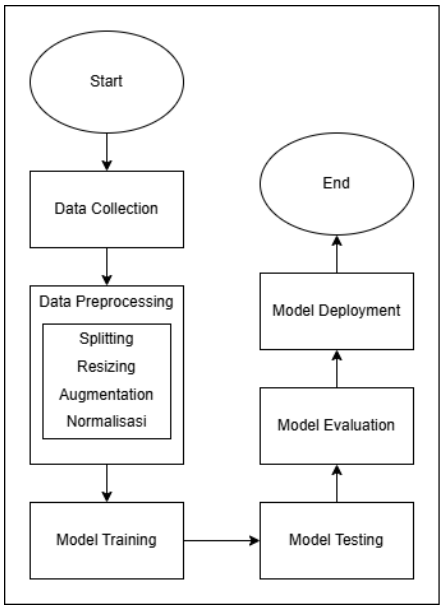

Gambar 3. Tahapan Penelitian

Data Collection

Pengumpulan data berupa citra dilakukan dengan metode *web scraping* di berbagai situs web medis opensource diantaranya DermNetNZ, Atlas of Clinical Dermatology, Dermatology Atlas, Dermatology Online Image Atlas, dan Hellenic Dermatological Atlas. Citra yang dikumpulkan merupakan citra dengan kondisi kulit seperti dermatomyositis, hidradenitis, lichen planus, psoriasis, vitiligo, dan healthy sehingga total akhir data citra keseluruhannya berjumlah 3.171.

Data Preprocessing

Data preprocessing tahapan yang dilakukan untuk mempersiapkan data sebelum digunakan dalam pembangunan model dan tahapan selanjutnya, *data preprocessing* ini terdapat beberapa proses diantaranya:

a. *Splitting data* yaitu proses membagi data berdasarkan rasio yang ditentukan yaitu 70% untuk *data training*, 15% untuk *data validation*, 15% untuk *data testing*.
b. *Resizing data* yaitu proses mengubah ukuran dimensi citra menjadi 224x224 *pixel* untuk keseluruhannya.
c. *Augmentation data* yaitu proses memperbanyak variasi data dengan menerapkan beberapa teknik transformasi seperti *rotation, shift, shear, zoom, flipping*, dan *nearest*. Setiap citra dibuatkan 4 variasi sehingga jumlah akhirnya menjadi 12.684 yang semula 3.171.
d. *Normalization data* yaitu proses mengubah nilai *pixel* suatu citra bertujuan untuk mendukung model dalam proses pelatihan, prosesnya mengubah rentang *pixel* suatu citra yang semula 0 hingga 255 menjadi 0 hingga 1.

Model Training

Tahapan ini dilakukan pembangunan model serta pelatihan model dengan menggunakan *data training* dan *data validation*. Pembangunan model menggunakan metode CNN dengan menginisialisasi parameter meliputi *Global Average Pooling* 2D *Layer*, *Batch Normalization layer, Dropout layer, flatten layer, dense layer, optimizer, loss function*. Proses *training* dengan menggunakan *data training* dan *data validation* akan divisualisasikan sebagai gambaran bagaimana model belajar.

Model Testing

Tahapan pengujian terhadap model yang telah dibangun dan terlatih dengan menguji menggunakan *data testing* yang bertujuan mengetahui sejauh mana model mampu melakukan prediksi yang akurat terhadap data yang belum pernah dilihat sebelumnya.

Model Evaluation

Tahap selanjutnya adalah melakukan evaluasi terhadap model dengan menggunakan confusion matrix, yang menghasilkan beberapa nilai performance metrics, yaitu: *accuracy, precision, recall*, dan F1-*score*.

Model Deployment

Tahapan ini mengimplementasikan model ke dalam aplikasi berbasis web dengan tujuan agar pengguna awam dapat menggunakan model ini dengan lebih mudah. Teknologi yang digunakan dalam tahap ini meliputi HTML, CSS, Python, JavaScript, dan Flask.

4. HASIL DAN PEMBAHASAN

Data Collection

Dataset citra yang berhasil terkumpul berjumlah 3.171 yang terdiri dari beberapa kondisi kulit diantaranya dermatomyositis, hidradenitis, lichen planus, psoriasis, vitiligo, dan healthy. Berikut ini pada Tabel 2 menyajikan jumlah di masing-masing kelas kondisi kulit.

Tabel 2. Jumlah Kelas Data

Kelas Data	**Jumlah Data**
Lichen Planus	541
Psoriasis	530
Vitiligo	537
Dermatomyositis	502
Hidradenitis	549
Healthy	512
Total Data	**3171**

Data Preprocessing

Tahapan ini dilakukan untuk mempersiapkan dataset sebelum digunakan untuk membangun model, melatih model, dan menguji model, tahapan ini terdiri dari beberapa proses diantaranya:

a. Splitting

Dataset dibagi menjadi tiga bagian yaitu untuk *data train, data validation*, dan *data testing*, dengan proporsi 70%:15%:15%. Berikut ini pada Tabel 3 menyajikan jumlah data pada *training, validation*, dan *testing*.

Tabel 3. Jumlah Data Training, Validation, dan Testing

Kelas Data	Data Training	Data Validation	Data Testing	Total Data
Lichen P.	378	81	82	541
Psoriasis	370	80	80	530
Vitiligo	375	81	81	537
Dermatomyositis	351	75	76	502
Hidradenitis	384	82	83	549
Healthy	358	77	77	512
Total Data	**2216**	**476**	**479**	**3171**

b. Resizing

Dataset pada penelitian ini awalnya memiliki dimensi yang bervariasi. Untuk mendukung proses pembangunan, pelatihan, dan pengujian model, seluruh dataset akan diubah ukurannya (*resizing*) sehingga dimensi setiap citra menjadi 224 x 224 pixel. Berikut ini pada Gambar 4 merupakan proses *resizing* pada ukuran dimensi dataset.

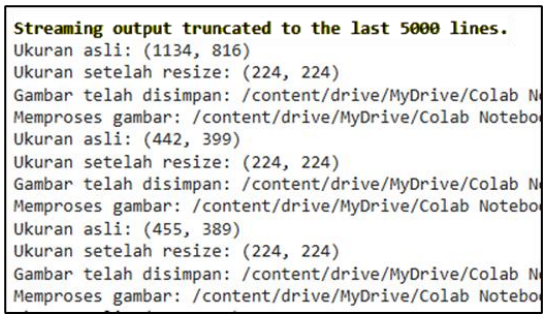

Gambar 4. Proses *Resizing*

c. Augmentation

Dataset yang dikumpulkan berjumlah 3.171 citra, sehingga diperlukan proses augmentasi untuk meningkatkan variasi data dan memperbesar jumlah dataset. Setiap citra akan diperbanyak menjadi empat variasi hasil augmentasi dengan menerapkan kombinasi beberapa transformasi, antara lain *rotation, shift, shear, zoom, flipping*, dan *nearest*. Dengan demikian, total akhir dataset setelah augmentasi menjadi 12.684 citra. Berikut ini Gambar 5 merupakan proses dilakukannya augmentasi.

Gambar 5. Proses *Augmentation*

Proses augmentasi dilakukan untuk meningkatkan variasi data, dari semula 3.171 citra menjadi empat kali lipat per citra, sehingga jumlah total citra setelah augmentasi mencapai 12.684. Tabel 4 menyajikan jumlah data pada masing-masing kelas beserta jenis datanya setelah dilakukan augmentasi.

Tabel 4. Jumlah Kelas Data Augmentasi

Kelas Data	Data Training	Data Validation	Data Testing	Total Data
Lichen P.	1512	324	328	2164
Psoriasis	1480	320	320	2120
Vitiligo	1500	324	324	2148
Dermatomyositis	1404	300	304	2008
Hidradenitis	1536	328	332	2196
Healthy	1432	308	308	2048
Total Data	**8864**	**1904**	**1916**	**12684**

d. Normalization

Dataset memiliki nilai piksel dari rentang 0 sampai dengan 255, sehingga dengan rentang tersebut dapat mengganggu proses pembangunan, pelatihan, dan penguji model, sehingga dilakukannya normalisasi dimana mengubah nilai piksel dari rentang 0 sampai dengan 1. Pada Gambar 6 merupakan proses sebelum dan sesudah dilakukannya proses normalisasi.

Sebelum Normalisasi	**Setelah Normalisasi**
... [18 22 31] [19 21 33] [19 21 33]]	... [0.07058824 0.08627451 0.12156864] [0.07450981 0.08235294 0.12941177] [0.07450981 0.08235294 0.12941177]]

Gambar 6. Proses Normalisasi

Model Training

Pada tahapan ini, terdapat dua proses utama yang dilakukan, yaitu pembangunan model dan proses pelatihan model untuk memperoleh performa yang optimal:

a. Pembangunan Model

Pada proses ini, dilakukan pembangunan arsitektur model *Convolutional Neural Network* (CNN) dengan menerapkan DenseNet121 sebagai *base model* yang berfungsi sebagai

feature extractor. Sementara itu, lapisan *Global Average Pooling* (GAP), *Batch Normalization*, *Dense*, dan *Dropout* digunakan sebagai bagian dari *classifier* untuk melakukan proses klasifikasi akhir. Pada Gambar 7 merupakan ilustrasi dari arsitektur model yang diterapkan pada penelitian ini.

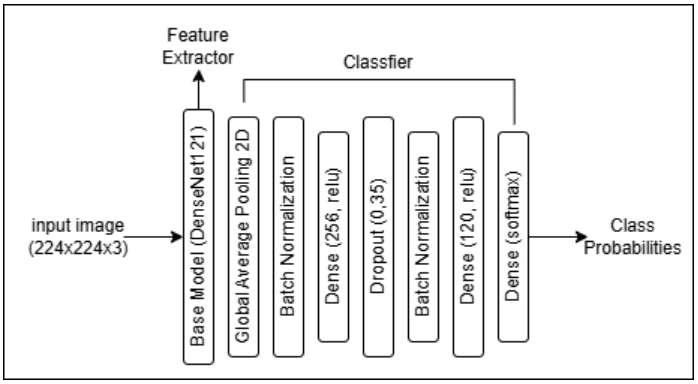

Gambar 7. Arsitektur Model CNN DenseNet121

b. Pelatihan Model

Pada proses ini, dilakukan proses pelatihan terhadap model yang telah dirancang arsitekturnya, menggunakan *data training* dan *data validation*. Pelatihan dilakukan dengan berbagai konfigurasi *batch size* dan jumlah *epoch* untuk mengevaluasi pengaruhnya terhadap performa model. Pada *original dataset*, peningkatan performa model terlihat signifikan untuk konfigurasi (16,20), (24,40), dan (32,60). Hal ini menunjukkan bahwa penyesuaian *batch size* dan jumlah *epoch* berkontribusi positif terhadap akurasi dan stabilitas model selama proses *training*.

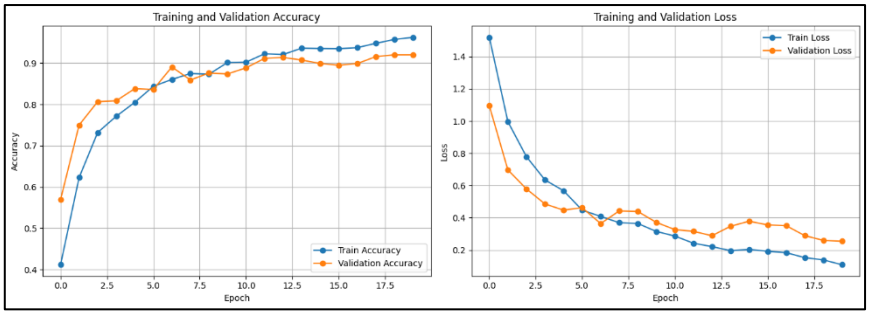

Gambar 8. Model 16/20 *Original Dataset*

Grafik pada Gambar 8 menunjukkan proses pelatihan model menggunakan *original dataset* dengan konfigurasi *batch size* 16 dan *epoch* 20, mengalami peningkatan secara stabil meskipun terdapat beberapa fluktuasi pada titik-titik tertentu.

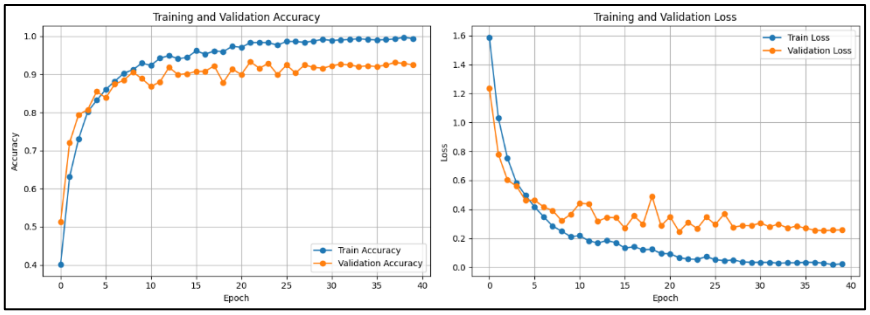

Gambar 9. Model 24/40 *Original Dataset*

Grafik pada Gambar 9 menunjukkan proses pelatihan model menggunakan *original dataset* dengan konfigurasi *batch size* 24 dan *epoch* 40, mengalami peningkatan secara stabil, fluktuasi di awal *epoch* lalu di akhir *epoch* mengalami indikasi awal *overfitting*.

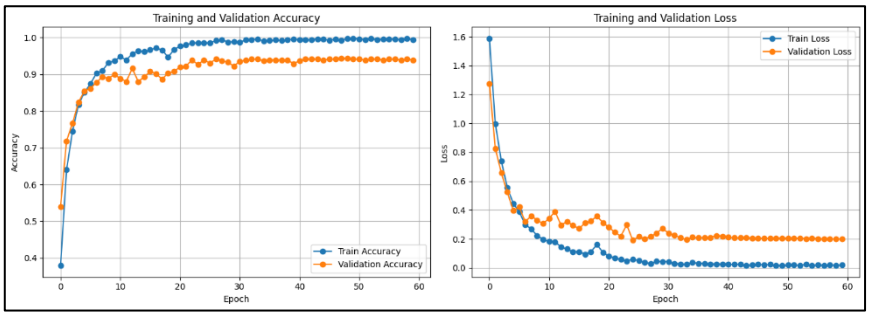

Gambar 10. Model 32/60 *Original Dataset*

Grafik pada Gambar 10 menunjukkan proses pelatihan model menggunakan *original dataset* dengan konfigurasi *batch size* 32 dan *epoch* 60, mengalami peningkatan secara stabil, fluktuasi di awal *epoch* lalu di akhir *epoch* mengalami indikasi *overfitting* tetapi jaraknya tidak terlalu jauh antara *train accuracy* dan *validation accuracy*.

Pada *augmented dataset*, peningkatan performa model terlihat signifikan untuk konfigurasi (16,20), (24,40), dan (32,60). Hal ini menunjukkan bahwa penyesuaian *batch size* dan jumlah *epoch* berkontribusi positif terhadap akurasi dan stabilitas model selama proses *training*.

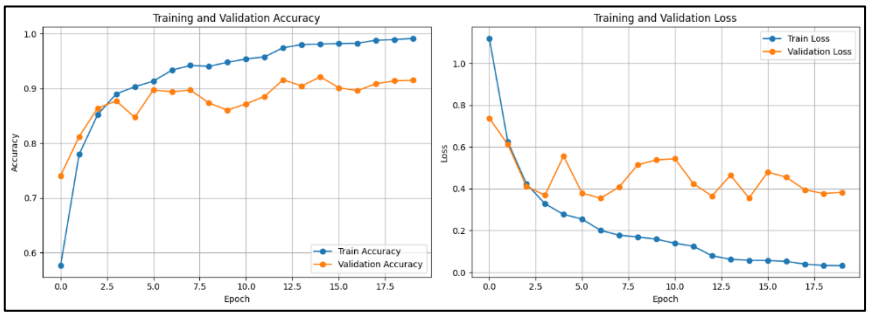

Gambar 11. Model 16/20 *Augmented Dataset*

Grafik pada Gambar 11 menunjukkan proses pelatihan model menggunakan *augmented dataset* dengan konfigurasi *batch size* 16 dan epoch 20, mengalami peningkatan dan beberapa fluktuasi pada titik-titik tertentu.

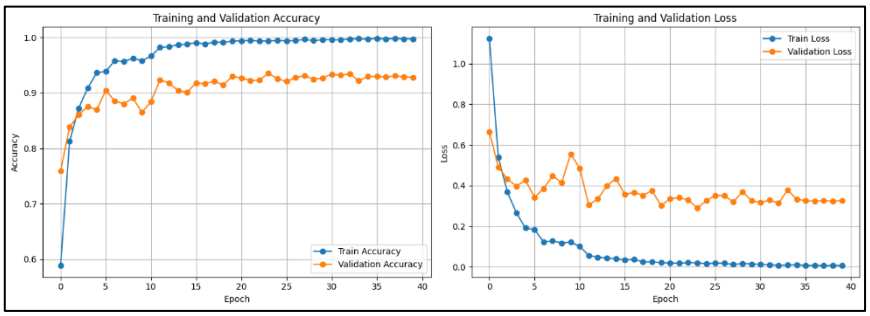

Gambar 12. Model 24/40 *Augmented Dataset*

Grafik pada Gambar 12 menunjukkan proses pelatihan model menggunakan *augmented dataset* dengan konfigurasi *batch size* 24 dan *epoch* 40, mengalami peningkatan secara stabil, fluktuasi di awal *epoch* lalu di akhir *epoch* mengalami indikasi awal *overfitting*.

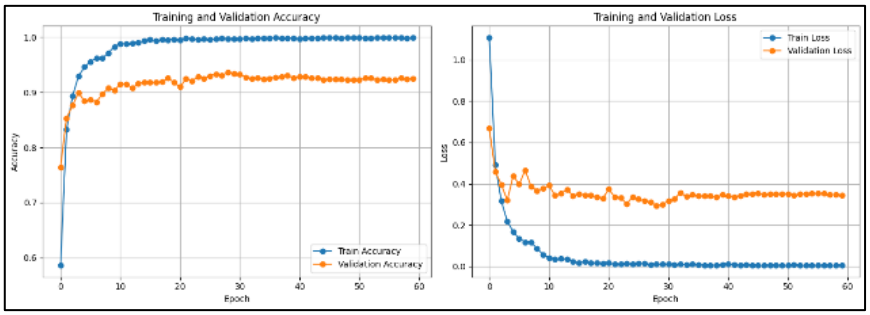

Gambar 13. Model 32/60 *Augmented Dataset*

Grafik pada Gambar 13 menunjukkan proses pelatihan model menggunakan *augmented dataset* dengan konfigurasi *batch size* 32 dan *epoch* 60, mengalami peningkatan secara stabil, fluktuasi di awal *epoch* lalu di akhir *epoch* mengalami indikasi *overfitting* tetapi jaraknya tidak terlalu jauh antara *train accuracy* dan *validation accuracy*.

Model Testing

Tahapan ini akan dilakukannya pengujian terhadap model yang telah dilatih dengan menggunakan *data testing*, yaitu data yang belum pernah dilihat oleh model selama proses pelatihan. Pada Tabel 5 menyajikan hasil akurasi pengujian pada model dengan *original dataset* dan *augmented dataset*.

Tabel 5. *Testing Original* dan *Augmented Dataset*

Original Dataset		
Batch Size	**Epoch**	**Akurasi**
16	20	90,40%
24	40	91,65%
32	60	91,44%
Augmented Dataset		
Batch Size	**Epoch**	**Akurasi**
16	20	92,07%
24	40	92,17%
32	60	92,43%

Model Evaluation

Tahapan ini akan dilakukannya evaluasi terhadap model yang telah terlatih dengan menggunakan *confusion matrix*. Evaluasi ini menghasilkan sejumlah metrik performa utama, yaitu *accuracy*, *precision*, *recall*, dan F1-*score*, yang digunakan untuk mengukur sejauh mana model mampu melakukan klasifikasi secara tepat. Berikut ini ilustrasi dari *confusion matrix* model dengan *original dataset*:

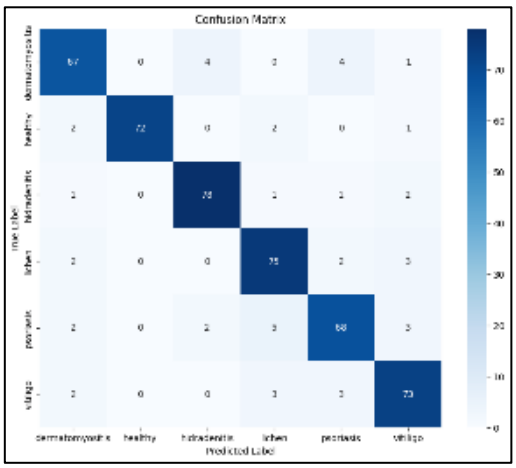

Gambar 14. *Confusion Matrix Model* 16/20 *Original Dataset*

Confusion matrix pada Gambar 14 mengindikasikan model berhasil melakukan identifikasi 433 dari 479 citra secara tepat, dengan 46 citra mengalami kesalahan klasifikasi.

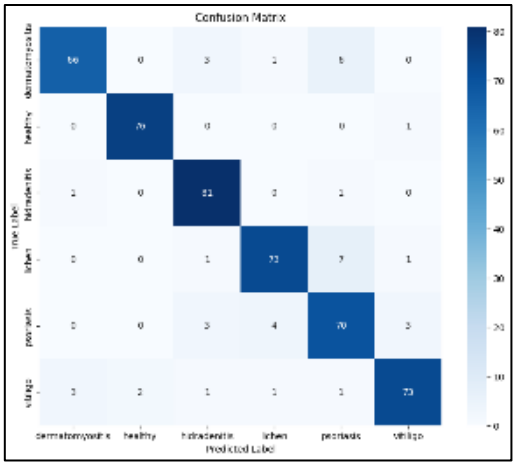

Gambar 15. *Confusion Matrix Model* 24/40 *Original Dataset*

Confusion matrix pada Gambar 15 mengindikasikan model berhasil melakukan identifikasi 439 dari 479 citra secara tepat, dengan 40 citra mengalami kesalahan klasifikasi.

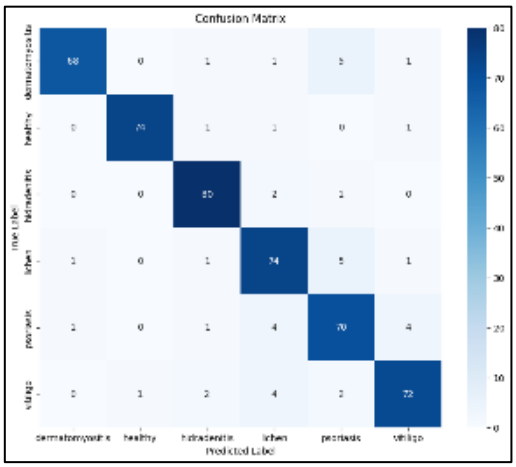

Gambar 16. *Confusion Matrix Model* 32/60 *Original Dataset*

Confusion matrix pada Gambar 16 mengindikasikan model berhasil melakukan identifikasi 438 dari 479 citra secara tepat, dengan 41 citra mengalami kesalahan klasifikasi.

Berikut ini merupakan ilustrasi *confusion matrix* dari model yang dilatih menggunakan *augmented dataset*:

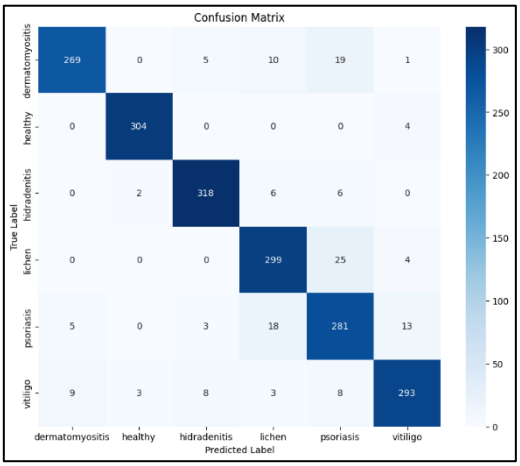

Gambar 17. *Confusion Matrix Model* 16/20 *Augmented Dataset*

Confusion matrix pada Gambar 17 mengindikasikan model berhasil melakukan identifikasi 1764 dari 1916 citra secara tepat, dengan 152 citra mengalami kesalahan klasifikasi.

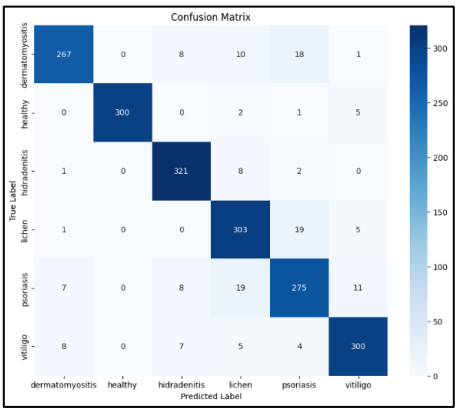

Gambar 18. *Confusion Matrix Model* 24/40 *Augmented Dataset*

Confusion matrix pada Gambar 18 mengindikasikan model berhasil melakukan identifikasi 1766 dari 1916 citra secara tepat, dengan 150 citra mengalami kesalahan klasifikasi.

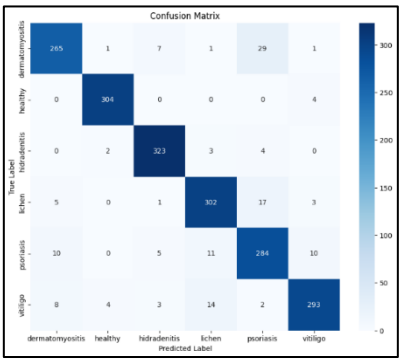

Gambar 19. *Confusion Matrix Model* 32/60 *Augmented Dataset*

Confusion matrix pada Gambar 19 mengindikasikan model berhasil melakukan identifikasi 1771 dari 1916 citra secara tepat, dengan 145 citra mengalami kesalahan klasifikasi.

Dari *confusion matrix* yang telah ditampilkan, diperoleh beberapa *performance matrics*, yaitu *accuracy*, *precision*, *recall*, dan F1-*score*, yang disajikan pada Tabel 6 berikut.

Tabel 6. *Performance Matrics Original* dan *Augmented Dataset*

Original Dataset					
Batch Size	**Epoch**	**Accuracy**	**Precision**	**Recall**	**F1-score**
16	20	90,40%	90,6%	90,4%	90,4%
24	40	91,65%	91,8%	91,8%	91,7%
32	60	91,44%	91,7%	91,7%	91,5%
Augmented Dataset					
Batch Size	**Epoch**	**Accuracy**	**Precision**	**Recall**	**F1-score**
16	20	92,07%	92,3%	92,1%	92,1%
24	40	92,17%	92,3%	92,1%	92,2%
32	60	92,43%	92,5%	92,4%	92,4%

Model Deployment

Tahapan ini mengimplementasikan model dengan performa terbaik, yaitu model yang dilatih menggunakan *augmented dataset* dengan konfigurasi *batch size* 32 dan *epoch* 60, ke dalam media berbasis *web*. *Framework Flask* digunakan untuk mengintegrasikan model tersebut dengan *interface web*. Pada Gambar 20 menampilkan *interface* bagian prediksi penyakit autoimun kulit, di mana pengguna dapat mengunggah gambar yang kemudian akan diproses dan diprediksi oleh sistem.

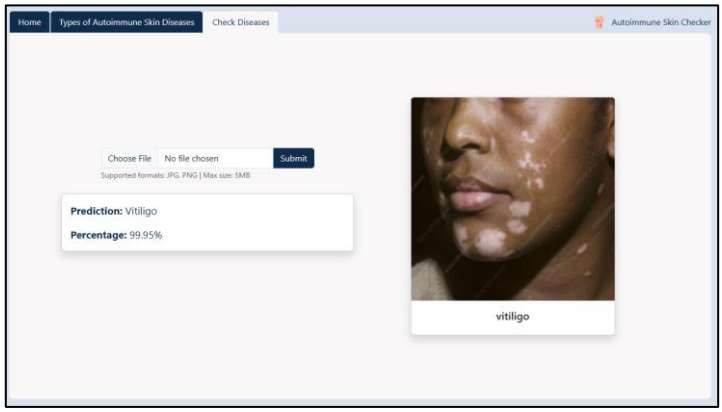

Gambar 20. ***Interface Deployment Model***

KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa penggunaan arsitektur DenseNet121 dengan dukungan teknik augmentasi data mampu meningkatkan performa model secara signifikan dibandingkan dengan *original dataset*. Variasi data yang lebih tinggi terbukti meningkatkan kemampuan generalisasi model, yang ditunjukkan oleh kenaikan pada metrik akurasi, presisi, *recall*, dan F1-*score*. Selain itu, konfigurasi *batch size* dan *epoch* juga turut mempengaruhi hasil pelatihan secara keseluruhan. Model CNN dengan arsitektur DenseNet121 pada konfigurasi batch size 32 dan epoch 60 dengan augmented dataset menunjukkan performa tertinggi, dengan nilai akurasi sebesar 92,43%, presisi 92,5%, recall 92,4%, dan F1-score 92,4%.

Sebagai saran untuk penelitian selanjutnya, disarankan untuk mengeksplorasi variasi data yang lebih luas, melakukan modifikasi pada arsitektur CNN yang digunakan, serta mempertimbangkan penerapan model pada platform mobile agar dapat diimplementasikan secara lebih luas.

DAFTAR REFERENSI

Albarbar, B., & Aga, H. (2024). A review on autoimmune diseases: Recent advances and future perspectives. Alq J Med App Sci, 7(3), 718–726. https://doi.org/10.54361/ajmas.247337

Bergqvist, C., & Ezzedine, K. (2020). Vitiligo: A review. Dermatology, 236(6), 571–592. https://doi.org/10.1159/000506103

Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., & 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

Boch, K., Langan, E. A., Kridin, K., Zillikens, D., Ludwig, R. J., & Bieber, K. (2021). Lichen planus. Frontiers in Medicine, 8, 737813. https://doi.org/10.3389/fmed.2021.737813

Hasan, N., Bao, Y., Shawon, A., & Huang, Y. (2021). DenseNet convolutional neural networks application for predicting COVID-19 using CT image. SN Computer Science, 2(1), 389. https://doi.org/10.1007/s42979-021-00782-7

Ingram, J. R. (2020). The epidemiology of hidradenitis suppurativa. British Journal of Dermatology, 183(6), 990–998. https://doi.org/10.1111/bjd.19435

Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. Electronic Markets, 31(3), 685–695. https://doi.org/10.1007/s12525-021-00475-2

Markoulidakis, I., Kopsiaftis, G., Rallis, I., & Georgoulas, I. (2021). Multi-class confusion matrix reduction method and its application on Net Promoter Score classification problem. In Proceedings of the 14th PErvasive Technologies Related to Assistive Environments Conference (PETRA '21) (pp. 412–419). https://doi.org/10.1145/3453892.3461323

Munandar, A. A., Farikhin, & Widodo, C. E. (2023). Sentimen analisis aplikasi belajar online menggunakan klasifikasi SVM. JOINTECS: Journal of Information Technology and Computer Science, 8(2), 77–84. https://doi.org/10.31328/jointecs.v8i2.4747

Putri, N. H., Jasril, Irsyad, M., Agustian, S., & Yanto, F. (2023). Klasifikasi citra stroke menggunakan augmentasi dan convolutional neural network EfficientNet-B0. Jurnal Media Informatika Budidarma, 7(2), 650–658. https://doi.org/10.30865/mib.v7i2.5981

Raharja, A., Mahil, S. K., & Barker, J. N. (2021). Psoriasis: A brief overview. Clinical Medicine, 21(3), 170–173. https://doi.org/10.7861/clinmed.2021-0257

Tanboon, J., Inoue, M., Saito, Y., Tachimori, H., Hayashi, S., Noguchi, S., Okiyama, N., Fujimoto, M., & Nishino, I. (2022). Dermatomyositis: Muscle pathology according to antibody subtypes. Neurology, 98(7), e739–e749. https://doi.org/10.1212/WNL.0000000000013176

Taye, M. M. (2023). Understanding of machine learning with deep learning: Architectures, workflow, applications and future directions. Computers, 12(5), 91. https://doi.org/10.3390/computers12050091

Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J., & Shen, F. (2023). Image data augmentation for deep learning: A survei. arXiv preprint arXiv:2204.08610. https://arxiv.org/abs/2204.08610

Yang, Z., Cherian, S., & Vucetic, S. (2023). Data augmentation for radiology report simplification. In Findings of the Association for Computational Linguistics: EACL 2023 (pp. 1922–1932). https://doi.org/10.18653/v1/2023.findings-eacl.144

Zhong, Z., Zheng, M., Mai, H., Zhao, J., & Liu, X. (2020). Cancer image classification based on DenseNet model. Journal of Physics: Conference Series, 1651(1), 012143. https://doi.org/10.1088/1742-6596/1651/1/012143