



## SEGMENTASI DAN KLASIFIKASI LESI KULIT MENGUNAKAN YOLO V11

**Rahayu Noveandini<sup>1</sup>, Maria Sri Wulandari<sup>2</sup>, Farhan Rasyad<sup>3</sup>**

Program Studi Sistem Informasi<sup>1</sup>, Sistem Informasi<sup>2</sup>, Informatika<sup>3</sup>  
Sistem Informasi<sup>1</sup>, Sistem Informas<sup>2</sup>, Teknik Industri<sup>3</sup>

Universitas Mahakarya Asia PSDKU Jakarta<sup>1</sup>, STMIK Jakarta STI&K<sup>2</sup>, Universitas Gunadarma<sup>3</sup>

\*Correspondent Author: [ayu.noveandini@gmail.com](mailto:ayu.noveandini@gmail.com)<sup>1</sup>,

Author Email: [mswuland@yahoo.com](mailto:mswuland@yahoo.com)<sup>2</sup>, [farharasyad13@gmail.com](mailto:farharasyad13@gmail.com)<sup>3</sup>

### In Indonesian

**Abstrak:** Kanker kulit menjadi ancaman serius jika tidak terdeteksi dini. Keterbatasan akses terhadap layanan dermatologi memerlukan solusi digital yang andal. Penelitian ini mengusulkan DermaScan, aplikasi web untuk diagnosis awal kanker kulit berbasis model YOLOv11 yang mampu melakukan segmentasi dan klasifikasi lesi kulit secara simultan. Model dilatih menggunakan dataset HAM10000 yang telah melalui pra-pemrosesan, termasuk augmentasi data dan konversi anotasi ke format YOLO. Proses pelatihan menggunakan GPU dan mixed precision untuk efisiensi. Evaluasi menunjukkan performa tinggi dengan mAP50 = 0,91 dan mAP50-95 = 0,735 untuk deteksi serta mAP50 (Seg) = 0,905 dan mAP50-95 (Seg) = 0,706 untuk segmentasi, membuktikan akurasi yang baik dalam memetakan dan mengenali lesi. Model dengan performa paling tinggi diimplementasikan ke dalam aplikasi web menggunakan Flask (backend) dan React.js (frontend) dengan antarmuka single-page application. Pengguna dapat mengunggah gambar lesi dan mendapatkan hasil prediksi real-time, termasuk jenis penyakit, tingkat keparahan, dan saran medis. DermaScan berfungsi sebagai alat bantu skrining non-invasif yang cepat dan mudah diakses. Sistem ini berpotensi meningkatkan kesadaran masyarakat dan mendukung tenaga medis dalam deteksi dini kanker kulit meskipun bukan pengganti diagnosis klinis.

**Kata kunci:** Segmentasi, Klasifikasi, Lesi Kulit, Deep Learning, YOLOv11

### In English

**Abstract:** Skin cancer poses a serious threat if not detected early. Limited access to dermatology services calls for a reliable digital solution. This study proposes DermaScan, a web application for the early diagnosis of skin cancer based on the YOLOv11 model, capable of simultaneously segmenting and classifying skin lesions. The model was trained using the pre-processed HAM10000 dataset, including data augmentation and conversion of annotations to the YOLO format. The training process utilized a GPU and mixed precision for efficiency. Evaluation results demonstrate high performance with mAP50 = 0.91 and mAP50-95 = 0.735 for detection, as well as mAP50 (Seg) = 0.905 and mAP50-95 (Seg) = 0.706 for segmentation, proving good accuracy in mapping and identifying lesions. The best performa model is implemented into a web application using Flask (backend) and React.js (frontend) with a single-page application interface. Users can upload images of lesions and receive real-time prediction results, including disease type, severity level, and medical recommendations. DermaScan serves as a fast and easily accessible non-invasive screening tool. This system has the potential to raise public awareness and support healthcare professionals in the early detection of skin cancer, although it is not a substitute for clinical diagnosis

**Keywords:** Segmentation, Classification, Skin Lesions, Deep Learning, YOLOv11



DOI: 10.52362/jisicom.v10i1.2302

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).



**Received:** 2026-03-22. **Revised:** 2026-04-26. **Accepted:** 2026-05-12 **Issue Period:** Vol.10 No.1 (2026), Pp. 127-142

## I. PENDAHULUAN

Kanker kulit termasuk salah satu jenis kanker dengan tingkat kejadian tertinggi di dunia. Berdasarkan data dari WHO, secara global setiap tahunnya kasus yang muncul diseluruh dunia terdapat 2 hingga 3 juta kasus kanker kulit non melanoma dan 132.000 kasus melanoma. Kanker ini juga menempati posisi sebagai satu dari tiga jenis kanker yang paling sering didiagnosis. Di Indonesia, kanker kulit menduduki peringkat ketiga dalam hal angka kejadian, setelah kanker serviks, ovarium, serta kanker payudara. Penyakit ini disebabkan oleh transformasi sel-sel kulit normal menjadi sel tumor. Beberapa faktor risiko utama yang dapat memicu kondisi ini meliputi paparan sinar ultraviolet (UV), infeksi virus, faktor genetik seperti ras berkulit putih, serta riwayat keluarga dengan kanker kulit [1].

Kanker kulit merupakan kondisi medis yang ditandai dengan proliferasi sel abnormal pada jaringan kulit, yang berpotensi melibatkan satu atau beberapa lapisan kulit sekaligus. Dalam mendiagnosis kanker kulit, metode biopsi sering digunakan, yaitu dengan mengambil sampel jaringan kulit untuk dianalisis lebih lanjut. Namun, prosedur biopsi ini memiliki kelemahan, seperti biaya yang relatif tinggi serta risiko kerusakan pada kulit. Penggolongan jenis kanker kulit melanoma melalui pendekatan *Convolutional Neural Network* (CNN) fokus pada pengembangan model CNN menghasilkan tingkat akurasi 92.64% sehingga dapat membantu membedakan antara tahi lalat normal dan melanoma pada citra kulit. [2]. Penelitian lainnya menekankan pentingnya deteksi dini untuk membantu masyarakat awam dalam mengidentifikasi gejala awal melanoma, yang sering kali mirip dengan tahi lalat biasa serta membandingkan dengan penelitian sebelumnya yang hanya mencapai akurasi 76% menggunakan CNN serupa [1]. Pada penelitian deteksi kanker kulit menggunakan YOLOv8 menghasilkan *recall* 0.969 dan *precision* 0.975 [3]. Sistem mampu melakukan klasifikasi kanker kulit berdasarkan kelasnya dengan hasil uji akurasi 99,50%, nilai presisi dan *recall* 99,75%, nilai *f1-score* 99,50%, dan nilai *loss* 0,0223 sehingga resiko keterlambatan diagnosis mampu dideteksi dini oleh sistem tersebut [4]. Arsitektur model 8 layer *Convolutional 2D* pada *Convolutional Neural Network* (CNN) dan memperoleh nilai keakuratan sebesar 75% dengan nilai *precision* dan *recall* paling tinggi yaitu sebesar 0,80 dan 0,82 serta nilai *f1\_score* sebesar 0,81 [5]. Tingkat akurasi diperoleh 90.63% pada klasifikasi kanker kulit menggunakan model *DenseNet121* [6]. Pada klasifikasi kanker kulit menggunakan CNN SVM menghasilkan nilai *accuracy* sebesar 65,33%, nilai *recall* sebesar 65,33%, nilai *precision* sebesar 68,51%, dan nilai *f1-score* sebesar 65,77% [7]. Klasifikasi jenis kanker kulit menggunakan arsitektur *VGG-16* dan *optimizer* Adam menghasilkan nilai akurasi 73,22% [8].

Dengan melihat keterbatasan tersebut, titik berat penelitian ini untuk memberikan solusi sebuah sistem yang mampu mendeteksi dan mengklasifikasi kanker kulit dengan tingkat akurasi yang lebih tinggi dan informatif dengan menggunakan model YOLOv11 yang tidak hanya mampu mengklasifikasikan jenis kanker kulit, tetapi juga mendeteksi lokasi lesi secara tepat. Selain itu, sistem akan diimplementasikan ke dalam bentuk aplikasi berbasis web agar lebih mudah diakses dan digunakan oleh tenaga medis maupun masyarakat umum.

Perancangan sistem deteksi kanker kulit menggunakan YOLOv11 bertujuan untuk meningkatkan kualitas diagnosis dan perawatan kanker kulit, serta memberikan dampak positif bagi masyarakat secara luas. Sistem ini diharapkan mencapai beberapa tujuan spesifik yaitu pertama, meningkatkan akurasi dan kecepatan dalam mendeteksi lesi kulit abnormal yang berpotensi menjadi kanker, kedua menyediakan alat bantu yang efisien dan mudah diakses oleh tenaga medis maupun masyarakat umum untuk memantau kondisi kulit dan merencanakan intervensi medis lebih awal, ketiga membantu mengurangi prevalensi kanker kulit dengan memungkinkan deteksi dini. Beberapa hal dibatasi pada penelitian ini yaitu : 1. Sistem ini dibuat untuk mendeteksi lesi kulit yang berkaitan dengan kanker kulit dan bukan mendeteksi suatu objek yang menandakan seberapa parah kanker itu terjadi, 2. Dataset yang diambil dari situs Datasetninja, yang hanya mengambil beberapa macam bentuk jenis Lesi kulit yang bersifat kanker atau non-kanker yang ada pada kulit yaitu *melanocytic nevi*, melanoma, *benign keratosis-like lesions*, *basal cell carcinoma*, *actinic keratoses* *actinic keratoses*, *vascular lesions* dan *dermatofibroma*, 3. Output dari model berupa citra kulit input yang dilengkapi dengan bounding box dan label kelas serta segmentasi pada area lesi, 4. Perolehan deteksi tidak bersifat diagnosis medis, melainkan sebagai informasi bagi penggunaan tentang kemungkinan jenis lesi pada citra input.

Dengan demikian, sistem ini tidak hanya berperan dalam meningkatkan kesehatan kulit secara keseluruhan, tetapi juga berkontribusi pada peningkatan kesadaran masyarakat terhadap bahaya kanker kulit dan



pentingnya pemeriksaan rutin. Implementasi model ini diharapkan dapat mengurangi beban penyakit serius terkait kanker kulit di masyarakat, serta memberikan dukungan dalam berbagai inisiatif dalam menghadapi tantangan kesehatan yang semakin beragam. Melalui pendekatan teknologi canggih seperti YOLOv11, sistem ini menjadi solusi inovatif yang dapat diakses oleh semua kalangan, sehingga memberikan manfaat yang lebih inklusif dan berkelanjutan bagi masyarakat.

## II. METODE DAN MATERI

### A. Metode

Pendekatan dalam penelitian ini melalui penerapan *Machine Learning Development Workflow*. Metode ini dipilih karena mampu memastikan kualitas model yang dikembangkan sekaligus mendukung eksperimen iteratif untuk optimasi performa sistem deteksi kanker kulit. Pendekatan *Machine Learning Development Workflow* mencakup enam tahapan utama yaitu :

#### 1. Pengumpulan data

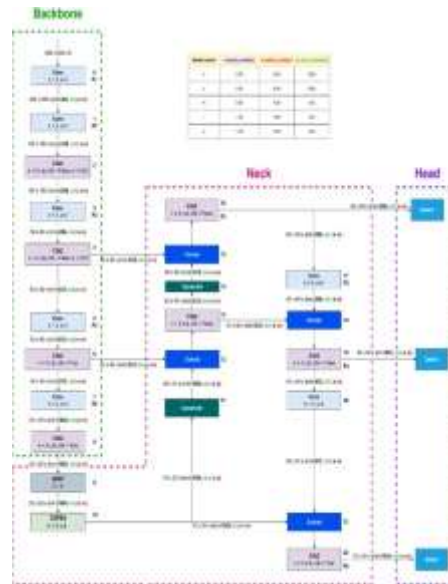
Penelitian ini memanfaatkan dataset **HAM10000** (*Human Against Machine with 10,000 training images*), yang terdiri atas 10.015 citra dermatoskopi lesi kulit. Dataset ini dikumpulkan selama dua dekade dari berbagai institusi, termasuk *Medical University of Vienna* (Austria) dan praktik kanker kulit di Queensland (Australia). Proses kurasi dilakukan secara semi-otomatis dengan bantuan arsitektur *InceptionV3* untuk klasifikasi awal, disertai verifikasi manual guna memastikan kualitas citra dan konsistensi anotasi. Dataset ini dipilih karena bersifat heterogen, terstandarisasi, serta telah menjadi *benchmark* pada banyak penelitian berbasis AI di bidang dermatologi.

#### 2. Analisis data awal (*exploratory data analysis* / EDA)

Proses EDA dilaksanakan guna menganalisis dan memahami sifat – sifat dasar dataset, termasuk pemetaan kelas dari *meta.json*, visualisasi pasangan citra asli dengan mask, serta analisis distribusi kelas. Hasil EDA menunjukkan adanya ketidakseimbangan distribusi data, sehingga langkah augmentasi perlu diterapkan pada kelas minoritas, seperti *basal cell carcinoma*, *dermatofibroma*, dan *vascular lesions*.

#### 3. Pra-pemrosesan data

Pra-pemrosesan mencakup decoding mask dari format bitmap Base64 menjadi citra *grayscale*, *filtering* data dengan membatasi kelas dominan (*melanocytic nevi*) hingga 2000 sampel, serta menghapus kelas yang dianggap kurang representatif (*actinic keratoses*). Dataset kemudian dibagi menjadi *train set* (70%) dan *validation set* (30%). Augmentasi data diterapkan melalui transformasi spasial (rotasi, *flip*, *crop* acak) maupun *fotometrik* (jitter warna), yang bertujuan meningkatkan variasi dan keseimbangan distribusi antar. Nama YOLO merupakan singkatan dari "You Only Look Once," yang menunjukkan kemampuannya untuk menyelesaikan deteksi dalam satu lintasan jaringan, berbeda dengan pendekatan sebelumnya yang memerlukan jendela geser diikuti oleh pengklasifikasi yang harus dijalankan berulang kali per gambar atau lebih. Metodenya terbagi menjadi dua yaitu, (1). mendeteksi proposal wilayah yang mungkin mengandung objek; (2). mengerjakan klasifikasi pada proposal tersebut. YOLO memberikan prespektif tentang deteksi obyek secara real-time [9]. YOLOv11 adalah versi terbaru dari rangkaian arsitektur YOLO (You Only Look Once) merupakan hasil pengembangan yang dilakukan oleh *Ultralytics*, dirilis pada tahun 2024. YOLOv11 menggabungkan inovasi arsitektural yang membuatnya lebih cepat dan akurat dibandingkan pendahulunya, menjadikannya salah satu teknologi paling mutakhir dalam bidang penglihatan komputer berbasis *Deep Learning* [10]. Gambar 1 menunjukkan arsitektur YOLOv11.




Gambar 1. Arsitektur YOLOv11

#### 4. Pelatihan model

Pelatihan model dilakukan menggunakan arsitektur YOLOv11s-seg, yaitu varian YOLOv11 untuk segmentasi dengan bobot *pretrained*. Pelatihan model dilaksanakan sebanyak 60 *epoch* dengan ukuran input  $640 \times 640$  piksel dan *batch size* 16. Optimisasi dilakukan menggunakan *stochastic gradient descent* dengan *learning rate* awal 0.01, momentum 0.937, dan *weight decay* 0.0005. Teknik augmentasi lanjutan, seperti *mosaic*, *mixup*, dan *copy-paste*, diterapkan secara langsung selama pelatihan untuk mencegah *overfitting*.

#### 5. Evaluasi model

Evaluasi model dilakukan pada subset validasi menggunakan metrik *precision*, *recall*, mAP50, dan mAP50-95, baik untuk deteksi (*bounding box*) maupun segmentasi (*mask*). Visualisasi hasil prediksi turut ditampilkan guna memberikan interpretasi kualitatif terhadap performa model. Model terbaik dipilih berdasarkan mAP50-95 tertinggi, kemudian diekspor dalam format ONNX untuk keperluan deployment. Hasil segmentasi tersaji pada gambar 2.



Gambar 2. Hasil Segmentasi

#### 6. Deployment.

Tahap akhir adalah *deployment* model ke dalam aplikasi web bernama **DermaScan**, dengan arsitektur *backend* berbasis Flask (Python) dan *frontend* berbasis React.js. Pengguna dapat mengunggah citra lesi kulit pada antarmuka web, kemudian sistem akan menjalankan inferensi menggunakan model YOLOv11 dan menampilkan hasil prediksi berupa label penyakit, tingkat keparahan, deskripsi singkat, serta



rekomendasi medis awal. Hasil ditampilkan secara visual melalui bounding box dan mask pada area lesi, dengan pewarnaan berbeda sesuai tingkat keparahan. Untuk pengujian publik, aplikasi di-hosting sementara menggunakan *ngrok*, sehingga dapat diakses secara daring.

Metodologi ini memastikan sistem yang dibangun dalam penelitian ini tidak hanya memenuhi standar keakuratan secara akademis, tetapi juga memiliki nilai aplikatif yang tinggi dan dapat digunakan sebagai alat bantu deteksi dini kanker kulit berbasis citra dermatoskop.

## B. Materi

### 2.1. Lesi Kulit

Lesi kulit secara umum didefinisikan sebagai perubahan struktural atau morfologis pada jaringan kulit , baik bersifat primer maupun sekunder, yang dapat disebabkan oleh berbagai kondisi medis seperti infeksi, trauma fisik, reaksi inflamasi, alergi, gangguan autoimun, paparan lingkungan, atau proses neoplastik. Lesi ini dapat terjadi pada semua lapisan kulit (epidermis, dermis, dan hipodermis), serta mencakup berbagai bentuk seperti goresan, robekan, abrasi, ruam, bercak pigmentasi, benjolan, lepuh (vesikel/bula), ulserasi, hingga perubahan tekstur atau warna kulit yang tidak normal. Dalam praktik klinis, lesi kulit sering menjadi manifestasi awal dari penyakit sistemik, baik yang bersifat infeksius (seperti leptospirosis, herpes zoster, selulitis, sifilis stadium dua) maupun non-infeksius (seperti psoriasis, dermatitis atopik, lupus eritematosus, atau ulkus diabetes). Lesi juga bisa bersifat tidak spesifik sehingga membutuhkan pemeriksaan lebih lanjut untuk menegakkan diagnosis pasti. Jurnal ini menekankan pentingnya kemampuan klinis dalam mengenali pola lesi kulit karena lesi tersebut sering kali menjadi petunjuk awal penyakit yang lebih serius, termasuk penyakit menular yang memerlukan tindakan darurat [11].

### 2.2. Convolutional Neural Network (CNN)

*Convolutional Neural Network* (CNN) merupakan salah satu arsitektur jaringan saraf tiruan yang secara khusus dirancang untuk mengolah data dengan topologi grid-like, seperti citra gambar. CNN terdiri dari lapisan konvolusi yang menggunakan filter (*kernel*) pada input untuk mendeteksi fitur lokal seperti tepi, tekstur, dan pola kompleks lainnya. Lapisan – lapisan tersebut kemudian dilanjutkan dengan lapisan *pooling* yang berfungsi untuk mereduksi dimensi data, serta lapisan *fully connected* yang bertugas melakukan proses klasifikasi akhir. CNN telah menunjukkan efektivitas yang tinggi dalam berbagai tugas pemrosesan citra, meliputi pengenalan, segmentasi dan klasifikasi gambar serta deteksi objek telah menjadi komponen penting dalam banyak aplikasi *deep learning* modern [12].

Dalam ranah *deep learning* (DL), *Convolutional Neural Networks* (CNN) merupakan arsitektur yang paling dominan dan secara luas sering diadopsi oleh peneliti. Karakteristik unggulan yang membedakan CNN dari metode sebelumnya terletak pada kemampuannya dalam mengekstraksi fitur-fitur relevan secara otomatis tanpa memerlukan keterlibatan manusia. CNN telah diimplementasikan secara luas di berbagai domain, seperti *computer vision*, pengolahan sinyal suara, hingga sistem deteksi wajah. Representasi model CNN mengadopsi dari mekanisme kerja *neuron* pada otak manusia dan hewan, serupa dengan jaringan saraf konvensional. Khususnya, di otak kucing, sekelompok sel kompleks membentuk korteks visual, dan urutan ini disimulasikan oleh CNN. *Goodfellow* dan rekan-rekannya mengidentifikasi tiga manfaat utama dari CNN representasi yang setara, konektivitas yang terbatas antar *neuron* pembagian parameter. Tidak seperti jaringan konvensional yang memiliki koneksi penuh antar *neuron*, CNN menerapkan mekanisme bobot yang digunakan secara bersama serta koneksi lokal guna mengoptimalkan pemrosesan struktur data input berdimensi dua, seperti halnya gambar. Operasi ini menggunakan sejumlah kecil parameter, yang menyederhanakan proses pelatihan dan mempercepat jaringan. Hal ini mirip dengan sel-sel korteks visual yang hanya merasakan sebagian kecil dari sebuah adegan daripada seluruh adegan, yaitu, sel-sel ini secara spasial mengekstrak korelasi lokal dalam input, seperti fluktuasi lokal di atas input [12]. Di dalam ranah *deep learning* (DL), *Convolutional Neural Networks* (CNN) merupakan algoritma yang paling dikenal luas dan banyak diimplementasikan. Keunggulan utama yang membedakan CNN dari metode sebelumnya terletak pada kapabilitasnya dalam melakukan ekstraksi fitur-fitur relevan secara mandiri tanpa bergantung pada keterlibatan manusia. Hal ini mirip dengan sel-sel

korteks visual yang hanya merasakan sebagian kecil dari sebuah adegan daripada seluruh adegan, yaitu, sel-sel ini secara spasial mengekstrak korelasi lokal dalam input, seperti fluktuasi lokal di atas input.


### 2.3. YOLOv11

YOLOv11 adalah model terbaru dalam keluarga YOLO (*You Only Look Once*) yang dirilis oleh Ultralytics tahun 2024. Model ini menawarkan lonjakan performa yang signifikan dalam berbagai permasalahan pada *computer vision* seperti deteksi objek, segmentasi instans, estimasi pose, pelacakan, dan klasifikasi gambar. YOLOv11 memperkenalkan beberapa komponen baru seperti blok C3k2, SPPF (*Spatial Pyramid Pooling-Fast*), dan C2PSA (*Convolutional Block with Parallel Spatial Attention*), yang meningkatkan kemampuan ekstraksi fitur dan akurasi deteksi objek. Selain itu, YOLOv11 menggunakan pendekatan tanpa anchor (*anchor-free*) dan dilengkapi dengan mekanisme perhatian (*attention mechanism*) untuk meningkatkan efisiensi dan kualitas deteksi. Sebagai model yang dirancang untuk *real-time object detection*, YOLOv11 menggabungkan inovasi arsitektural yang membuatnya lebih cepat dan akurat dibandingkan pendahulunya, menjadikannya salah satu teknologi paling mutakhir dalam bidang penglihatan komputer berbasis *deep learning* [11].

## III. PEMBAHASAN DAN HASIL

Tahapan pengembangan mengikuti metode *Machine Learning Development Workflow*, yaitu pendekatan sistematis dalam pengembangan model *Machine Learning* dari pengumpulan data hingga evaluasi dan *deployment*. Pendekatan ini dipilih karena mampu menjamin kualitas dan reliabilitas model yang dikembangkan, serta mendukung eksperimen iteratif yang sering diperlukan dalam optimasi model deteksi kanker kulit. Metodologi ini terdiri dari beberapa tahapan utama:

1. Pengumpulan data (Data Collecting)
2. Analisis data awal (Exploratory Data Analysis / EDA)
3. Pra-pemrosesan data (Data Preprocessing)
4. Pelatihan model (Model Training)
5. Evaluasi model (Model Evaluation)
6. Deployment (Implementasi model)




Gambar 3. Machine Learning Development Workflow

Gambar 3 menunjukkan tahapan pengembangan aplikasi yang menggunakan metode *Machine Learning Workflow* proses dimulai dengan *Data Collecting* , di mana data awal dikumpulkan untuk analisis. Selanjutnya, dilakukan *Explanatory Data Analysis* untuk memahami pola dan karakteristik data. Setelah itu, *Data Preprocessing* dilakukan untuk membersihkan dan mengubah data menjadi format yang siap digunakan. Tahap selanjutnya yaitu *Training Model*, di mana model *Machine Learning* diajarkan menggunakan data yang telah diproses.

Tahapan :

#### 1. Pengumpulan data

Dataset yang digunakan dalam penelitian ini adalah HAM10000 (*Human Against Machine* with 10.000 *training images*), yang terdiri dari 10.015 gambar Dermatoskopi. Dataset ini dapat diakses melalui platform Dataset Ninja pada tautan berikut: <https://datasetninja.com/skin-cancer-ham10000>. Dataset ini dirancang untuk mengatasi keterbatasan dataset sebelumnya yang cenderung kecil dan kurang representatif. HAM10000 dikumpulkan selama lebih dari dua dekade dari berbagai sumber seperti Departemen Dermatologi di *Medical University of Vienna*, Austria, dan sebuah klinik kulit di Queensland, Australia. Proses pengumpulan data dilakukan secara semi-otomatis dengan memanfaatkan model InceptionV3 untuk mengklasifikasikan jenis gambar, serta proses manual untuk memastikan kualitas akhir dataset. Tampilan dataset pada *platform* dataset Ninja tersaji pada gambar 4.




Gambar 4. Tampilan Dataset Pada Platform Dataset Ninja

## 2. Hasil Pra-Pemrosesan Data (Data Preprocessing)

Pada tahap ini, dataset mentah diproses dan dipersiapkan agar siap digunakan untuk pelatihan model deteksi segmentasi menggunakan YOLOv11. Proses dimulai dari pemrosesan anotasi hingga pembuatan file konfigurasi YOLO dengan tujuan memastikan data memiliki format yang sesuai dengan kebutuhan model dan meningkatkan kualitas pelatihan.

Proses dimulai dengan mendekode mask yang berupa bitmap Base64 yang dikompresi menjadi gambar mask dalam mode grayscale, di mana data mask pada dataset disimpan dalam format tersebut; fungsi `decode_mask()` digunakan untuk melakukan dekode dan mengembalikan mask ke bentuk gambar grayscale melalui beberapa tahap, yaitu: *decode string Base64*, dekompresi menggunakan *zlib*, konversi ke gambar *grayscale* dengan PIL, serta penempatan mask pada posisi aslinya berdasarkan informasi origin. Hasilnya menunjukkan bahwa dataset mulai seimbang, meskipun terdapat beberapa kelas yang masih sedikit belum seimbang. Namun, ketidakseimbangan tersebut tidak terlalu memengaruhi proses pelatihan karena data telah melalui augmentasi sebelumnya, sehingga variasi data sudah cukup baik. Gambar 5 menunjukkan hasil jumlah data per kelas setelah augmentasi.



Gambar 5. Hasil Jumlah Data Per Kelas Setelah Augmentasi

Setelah proses augmentasi, langkah selanjutnya adalah mengonversi mask yang tersimpan dalam format RGB ke *grayscale* menggunakan fungsi *convert\_rgb\_masks\_to\_grayscale()*, yang bertujuan untuk mempersiapkan data guna ekstraksi kontur dan konversi ke format YOLO.

### 3. Hasil Pelatihan Model (Model Training)

Pada tahap model training , model YOLOv11 digunakan untuk melakukan tugas deteksi dan segmentasi objek pada dataset HAM10000. Model yang digunakan adalah yolo11s-seg.pt, yaitu versi kecil dari YOLOv11 yang telah dilatih sebelumnya (pretrained) dan dirancang khusus untuk tugas segmentasi. Lalu model pretrained dimuat.

```
# Load model YOLOv11 untuk segmentasi
model = YOLO("/kaggle/input/yolov11s-seg/other/default/1/yolo11s-seg.pt")
```

Gambar 6. Kode Untuk Memuat Model YOLOv11 Untuk Melakukan Proses Training

Setelah seluruh konfigurasi dan persiapan selesai, proses pelatihan model pun dimulai. Berikut adalah hasil pelatihan untuk 10 epoch pertama:

Tabel 1. Distribusi Loss Pada Epoch Pertama

Epoch	box_loss	seg_loss	cls_loss
1/60	0.007985	0.01753	2.204
2/60	0.008143	0.01693	1.76
3/60	0.008092	0.01682	1.688
4/60	0.007862	0.01653	1.618
5/60	0.007583	0.01624	1.533
6/60	0.00742	0.01581	1.485
7/60	0.007412	0.01596	1.456
8/60	0.007315	0.0157	1.427
9/60	0.007245	0.01542	1.393
10/60	0.007079	0.01519	1.366

Tabel 2. Distribusi Metrik Pelatihan Pada 10 Epoch Terakhir

Box(P)	Box(R)	Box(mAP50)	Box(mAP 50-95)	Mask(P)	Mask(R)	Mask(mAP50)	Mask(mAP50-95)
0.476	0.614	0.507	0.334	0.473	0.61	0.506	0.323
0.601	0.628	0.604	0.425	0.609	0.628	0.595	0.389
0.481	0.578	0.559	0.368	0.471	0.575	0.542	0.345
0.56	0.678	0.62	0.436	0.559	0.68	0.614	0.415
0.436	0.548	0.471	0.336	0.458	0.516	0.458	0.319
0.561	0.703	0.668	0.469	0.559	0.703	0.661	0.437
0.576	0.648	0.619	0.434	0.564	0.603	0.598	0.382
0.702	0.672	0.719	0.516	0.677	0.648	0.684	0.43
0.634	0.662	0.654	0.497	0.632	0.658	0.65	0.476
0.642	0.724	0.74	0.536	0.641	0.723	0.738	0.508

Dari kedua tabel yang diberikan, dapat disimpulkan bahwa proses pelatihan model telah mencapai hasil yang cukup baik setelah 10 *epoch* pertama. Tabel 1 menunjukkan distribusi nilai *loss* (kerugian) selama 10 *epoch* pertama pelatihan, dengan tiga jenis *loss* yaitu *box\_loss*, *seg\_loss*, dan *cls\_loss*. Nilai-nilai ini secara keseluruhan menunjukkan tren penurunan seiring berjalannya *epoch*, yang menandakan bahwa model sedang belajar dengan baik dan mengoptimalkan parameter-parameter. Tabel 2 memberikan informasi tentang distribusi metrik pelatihan pada 10 *epoch* terakhir, termasuk *Box Precision* (P), *Box Recall* (R), *Box mAP50-95*, *Mask Precision* (P), *Mask Recall* (R), dan *Mask mAP50-95*. Metrik-metrik ini digunakan untuk mengukur performa model dalam deteksi objek (bounding box) dan segmentasi mask. Setelah pelatihan berlangsung hingga tahap pertengahan, tabel 3 dan 4 adalah hasil untuk 10 *epoch* pada fase tersebut.

Tabel 3. Distribusi Loss Pada 10 Epoch Pertengahan

Epoch	box_loss	seg_loss	cls_loss
31/60	0.006048	0.01317	1.03
32/60	0.006094	0.0133	1.013
33/60	0.006031	0.01318	0.999
34/60	0.00607	0.01327	1.015
35/60	0.00597	0.01314	0.9951
36/60	0.005937	0.01297	0.9683
37/60	0.006007	0.0132	0.9691
38/60	0.005888	0.01303	0.9644
39/60	0.005781	0.01268	0.933
40/60	0.005864	0.01292	0.9303

Tabel 4. Distribusi Metrik Pelatihan Pada 10 Epoch Pertengahan

Box(P)	Box(R)	Box(mAP50)	Box(mAP 50-95)	Mask(P)	Mask(R)	Mask(mAP 50)	Mask(mA P50-95)
0.79	0.81	0.872	0.661	0.785	0.807	0.864	0.629
0.782	0.779	0.858	0.663	0.781	0.78	0.857	0.639
0.812	0.808	0.87	0.668	0.81	0.807	0.864	0.638
0.79	0.804	0.854	0.667	0.791	0.804	0.853	0.643
0.813	0.815	0.873	0.684	0.813	0.815	0.872	0.648
0.825	0.833	0.884	0.695	0.825	0.833	0.884	0.67
0.793	0.813	0.867	0.676	0.795	0.828	0.877	0.656
0.824	0.839	0.881	0.692	0.824	0.836	0.883	0.663
0.84	0.813	0.885	0.702	0.838	0.812	0.884	0.673
0.846	0.778	0.876	0.699	0.845	0.777	0.875	0.666

Dari kedua tabel yang diberikan, dapat disimpulkan bahwa pada fase pertengahan pelatihan (*epoch* ke-31 hingga *epoch* ke-40), model menunjukkan performa yang lebih stabil dan cenderung konvergen. Tabel 3 menampilkan distribusi nilai *loss* selama 10 *epoch* ini, dengan tiga jenis *loss* yaitu *box\_loss*, *seg\_loss*, dan *cls\_loss*. Nilai-nilai ini secara keseluruhan menunjukkan tren penurunan yang lebih lambat dibandingkan dengan fase awal, tetapi tetap menunjukkan perbaikan meskipun dalam skala yang lebih kecil. Misalnya, nilai *box\_loss* berkurang dari 0.006048 pada *epoch* ke-31/60 menjadi 0.005864 pada *epoch* ke-40/60, sementara *seg\_loss* mengalami penurunan dari 0.01317 menjadi 0.01292. Namun nilai *cls\_loss* menunjukkan fluktuasi yang lebih besar, mulai dari 1.03 pada *epoch* ke-31/60 hingga mencapai puncak 1.015 pada *epoch* ke-34/60 sebelum kembali menurun menjadi 0.9303 pada *epoch* terakhir. Tabel 4 memberikan informasi tentang distribusi metrik pelatihan pada 10 *epoch* pertengahan, termasuk *Box Precision* (P), *Box Recall* (R), *Box mAP50-95*, *Mask Precision* (P), *Mask Recall* (R), dan *Mask mAP50-95*. Metrik-metrik ini menunjukkan bahwa performa model secara keseluruhan telah meningkat signifikan dibandingkan dengan fase awal. Pada tahap ini, nilai *Box Precision* berkisar antara 0.782 hingga 0.846, sedangkan *Box Recall* berkisar antara 0.779 hingga 0.778. *Box mAP50-95* juga mencapai nilai tertinggi 0.876 pada *epoch* terakhir, menunjukkan model semakin baik dalam kemampuannya mendeteksi objek secara akurat. Untuk segmentasi *mask*, *Mask Precision* dan *Mask Recall* menunjukkan stabilitas yang baik, dengan nilai berkisar antara 0.785 hingga 0.845 dan 0.807 hingga 0.777, masing-masing. Selain itu, *Mask mAP50-95* mencapai nilai maksimum 0.875 pada *epoch* terakhir, menandakan model mampu melakukan yang lebih baik dalam segmentasi objek secara detail. Setelah pelatihan model berlangsung hingga tahap akhir, tabel 5 dan 6 adalah hasil untuk 10 *epoch* terakhir.

Tabel 5. Distribusi Loss pada 10 Epoch Terakhir

Epoch	box_loss	seg_loss	cls_loss
51/60	0.004705	0.00995	0.4876
52/60	0.004586	0.00948	0.4395
53/60	0.004518	0.009435	0.4399
54/60	0.004444	0.009261	0.4089
55/60	0.004379	0.009258	0.4013
56/60	0.004273	0.009021	0.3901
57/60	0.004197	0.009026	0.3825
58/60	0.004116	0.009022	0.3565
59/60	0.00407	0.008913	0.3579
60/60	0.003993	0.008783	0.3426

Tabel 6. Distribusi Metrik pada Pelatihan 10 Epoch Terakhir

Box(P)	Box(R)	Box(mAP50)	Box(mAP50-95)	Mask(P)	Mask(R)	Mask(mAP50)	Mask(mAP50-95)
0.823	0.809	0.888	0.715	0.824	0.81	0.887	0.683
0.878	0.806	0.897	0.724	0.874	0.803	0.892	0.689
0.844	0.829	0.898	0.724	0.836	0.82	0.893	0.69
0.837	0.829	0.9	0.729	0.834	0.827	0.897	0.697
0.859	0.827	0.904	0.73	0.858	0.824	0.901	0.7
0.848	0.843	0.905	0.728	0.846	0.838	0.902	0.698
0.835	0.847	0.903	0.732	0.833	0.845	0.902	0.699
0.858	0.844	0.91	0.735	0.854	0.841	0.905	0.703
0.833	0.85	0.902	0.735	0.845	0.839	0.905	0.705
0.833	0.874	0.904	0.735	0.834	0.875	0.907	0.706

#### 4. Hasil Evaluasi Model

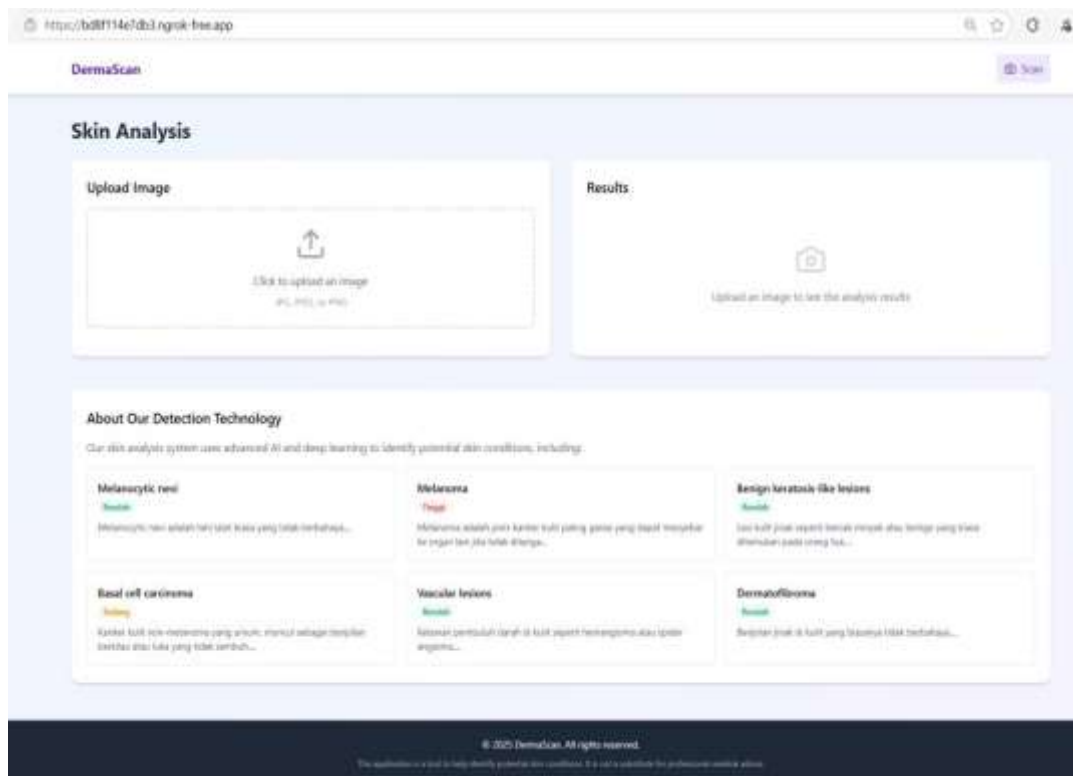
Hasil visualisasi prediksi menunjukkan pada gambar 7 bahwa model berhasil mendeteksi lesi kulit sebagai *melanocytic nevi* dengan tingkat kepercayaan (confidence score) sebesar 0.89, yang ditandai oleh *bounding box* berwarna merah di sekitar objek. Gambar memiliki resolusi 480x640 , dan hasil prediksi ini dilakukan dengan waktu *preprocessing* sekitar 2.9 ms , inferensi sekitar 64.8 ms , serta *postprocessing* sekitar 22.9 ms per gambar, pada ukuran input (1, 3, 480, 640). Hasil menjelaskan bahwa model tidak hanya akurat pada identifikasi kelas lesi kulit, tetapi juga efisien dalam waktu eksekusi. Keseluruhan proses evaluasi ini bertujuan untuk memastikan model mempunyai kinerja yang optimal, generalisasi yang baik, serta siap untuk digunakan dalam tahap *deployment*.



Gambar 7. Hasil Visualisasi Pada Objek yang Terdeteksi

## 5. Deploymen

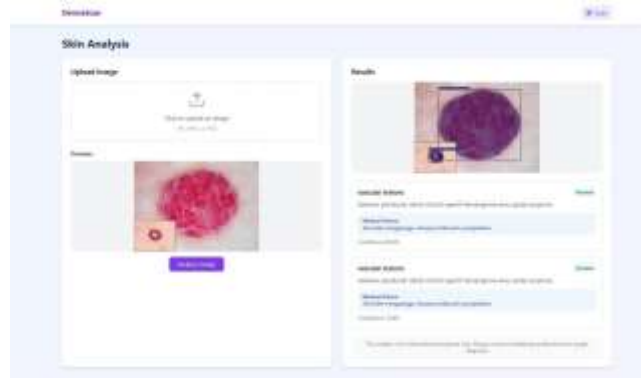
Pada tahap *deployment* model YOLOv11 hasil pelatihan diimplementasikan ke dalam sebuah aplikasi web berbasis *Flask* sebagai *backend* dan antarmuka pengguna berbasis HTML, CSS, JavaScript dengan React.js sebagai *frontend*. Arsitektur sistem dibangun dengan pendekatan *Model-View-Controller* (MVC), di mana *Flask* bertindak sebagai *controller* yang menghubungkan antara model deteksi penyakit kulit dan antarmuka pengguna. *Backend* dibuat menggunakan *Python* dengan *framework Flask*, yang menyediakan *endpoint/detect* untuk menerima unggahan gambar dari pengguna, memprosesnya melalui model YOLOv11, dan mengembalikan hasil prediksi beserta informasi medis terkait. Di sisi *frontend*, antarmuka web dikembangkan menggunakan HTML, CSS, dan JavaScript dengan komponen dinamis menggunakan React.js.



Gambar 8. Tampilan Antar Muka DermaScan

Gambar 8 menunjukkan tampilan antarmuka utama dari *website* DermaScan, yang dirancang sebagai alat deteksi awal lesi kulit berbasis *web*. Halaman ini terdiri dari dua bagian utama: area unggah gambar (*Upload Image*) di sebelah kiri, yang memungkinkan pengguna mengunggah foto lesi kulit untuk analisis, dan area hasil deteksi (*Results*) di sebelah kanan, yang akan menampilkan hasil prediksi setelah proses inferensi selesai.

Gambar 9 dan 10 menunjukkan hasil uji coba pada *website* DermaScan yang menggambarkan proses deteksi lesi kulit secara langsung. Pada bagian kiri, pengguna dapat melihat area unggah gambar (*Upload Image*) dengan pratinjau gambar lesi kulit yang telah diunggah. Setelah pengguna mengklik tombol *Analyze Image*, sistem melakukan inferensi menggunakan model YOLOv11 dan menampilkan hasilnya di bagian kanan halaman.



Gambar 9. Tampilan Saat Mendeteksi Lesi Kulit



Gambar 10. Tampilan Result Pada Gambar Yang Terdeteksi



Hasil deteksi menunjukkan dua prediksi untuk jenis lesi kulit yaitu *vascular lesions*. Untuk setiap prediksi, ditampilkan tingkat keparahan (*severity*), deskripsi kondisi, saran medis (*medical advice*), serta skor kepercayaan (*confidence*) dari model. Dalam contoh ini, kedua prediksi memiliki tingkat keparahan "Rendah" dan disertai dengan saran medis bahwa lesi tersebut biasanya tidak memerlukan pengobatan jika tidak mengganggu. Skor kepercayaan untuk kedua prediksi masing-masing adalah 94.0% dan 74.8%, yang menunjukkan tingkat akurasi dari hasil deteksi.

Pada bagian hasil (*Results*), terdapat visualisasi gambar hasil deteksi dengan bounding box yang menandakan lokasi lesi kulit yang terdeteksi. Selain itu, aplikasi juga memberikan peringatan bahwa analisis ini hanya bersifat informasi tambahan dan bukan pengganti konsultasi profesional dengan tenaga medis. Tampilan keseluruhan antarmuka dirancang agar pengguna dapat dengan mudah memahami hasil deteksi serta mendapatkan informasi tambahan yang relevan sebelum mengambil tindakan lebih lanjut.

#### IV. KESIMPULAN

Berdasarkan hasil uji coba penelitian dapat ditarik kesimpulan yaitu:

1. Penelitian ini berhasil merancang serta membangun sistem pendeteksian kanker kulit berbasis *computer vision* menggunakan model YOLOv11. Model ini mampu mendeteksi lokasi lesi kulit melalui *bounding box* dan melakukan segmentasi area lesi secara akurat berdasarkan citra medis. Model yang dikembangkan tidak hanya mendeteksi dan mensegmentasi lesi kulit, tetapi juga mampu mengklasifikasikannya ke dalam beberapa kategori jenis lesi kulit yang terkait dengan kanker kulit berdasarkan dataset HAM10000. Informasi kelas hasil deteksi dilengkapi dengan detail seperti nama penyakit, tingkat keparahan, deskripsi, dan saran medis awal.
2. Hasil Kinerja model YOLOv11 diukur menggunakan metrik evaluasi seperti mAP, *Precision*, dan *Recall*. Untuk deteksi objek (*bounding box*), diperoleh mAP50 sebesar 0.9145, mAP50-95 0.7400, *Precision* 0.8902, dan *Recall* 0.8140. Pada tugas segmentasi, model mencapai mAP50 0.9117, mAP50-95 0.7086, *Precision* 0.8888, dan *Recall* 0.8129. Nilai tersebut membuktikan bahwa model memiliki akurasi tinggi, estimasi yang tepat, serta kemampuan mendeteksi objek secara komprehensif.
3. Hasil implementasi sistem ini berupa aplikasi berbasis *web* (DermaScan) menggunakan *framework Flask (backend)* dan *React (frontend)*. Aplikasi ini menyediakan antarmuka yang responsif dan informatif, memungkinkan pengguna untuk mengunggah gambar kulit, menjalankan deteksi melalui model YOLOv11, dan melihat hasilnya secara visual (*bounding box & mask*) serta informasi terkait penyakit yang terdeteksi. Ini memberikan alternatif metode diagnosis awal yang lebih cepat, murah, dan non-invasif.

Dengan demikian, tujuan penelitian untuk merancang dan mengembangkan sistem pendeteksian kanker kulit menggunakan YOLOv11 yang akurat dan non-invasif serta mengimplementasikannya dalam bentuk aplikasi *web* sebagai alat bantu diagnosis awal telah tercapai.

#### REFERENSI

- [1] N.Martin and D. Udjulawa, "Klasifikasi Kanker Kulit Pada Citra Dermatoskopi Menggunakan CNN", *Jurnal Algoritme*, Vol. 5, No. 1, 2024, pp. 35 – 46.
- [2] R.R. Saputra, A. Junaidi and W.A. Saputra, "Klasifikasi Penyakit Kanker Kulit Menggunakan Metode Convolutional Neural Network (Studi Kasus: Melanoma)", *Jurnal of Dinda, Institut Teknologi Telkom Purwokerto*, Vol. 2, No. 1, 2022, pp. 52-57.
- [3] E.N.D. Tanadi, D.S.Y. Kartika and A.R.E. Najaf, "Sistem Pendeteksi Penyakit Kanker Kulit Menggunakan Convolutional Neural Network Arsitektur YOLOv8 Berbasis Website", *Neptunus: Jurnal Ilmu Komputer Dan Teknologi Informasi*, Vol. 2, No. 3, 2024, pp. 117-129.
- [4] D.A. Nurlitasari, R. Magdalena and R.Y.N. Fu'adah, "Analisis Performansi Sistem Klasifikasi Kanker Kulit Menggunakan Convolutional Neural Network", *Journal of Electrical and System Control Engineering*, Vol. 5, No. 2, 2022, pp. 91–99.



- [5] L. Hakim, Z. Sari and Handhajani, “Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network”, *Jurnal Resti (Rekayasa Sistem dan Teknologi Informasi)* Vol. 5 No. 2, 2021, pp 379 – 385.
- [6] M.R. Ashari, Z. Sari and D.R. Chandranegara, “Klasifikasi Kanker Kulit Menggunakan Metode Deep Learning”, *Jurnal Repositor*, Vol. 6, No. 1, 2024, pp.11-16.
- [7] R. Yohannes and M. E. Al Rivan, “Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM”, *J. Algoritm*, Vol. 2, No. 2, 2022, pp. 133–144.
- [8] Orlando and M.E. Al Rivan, *Klasifikasi Jenis Kanker Kulit Manusia Menggunakan Convolutional Neural Network*, 2<sup>nd</sup> MDP Student Conference (MSC), 2023, pp.144-150.
- [9] J. Terven, D. Cordova-Esparza and J. Romero-Gonzalez, “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS”, *MDPI Journal*, 2023, pp.1680-17165, <https://doi.org/10.3390/make5040083>.
- [10] P. Hidayatullah, N. Syakarni, M.R. Sholahuddin, T. Gelar and R. Tubagus, “YOLOv8 to YOLO11: A Comprehensive Architecture In-depth Comparative Review A PREPRINT”, 2025.
- [11] T. Skuhala, V. Trkulja, M. Rimac, A. Dragobratović and B. Desnica, “Analysis of Types of Skin Lesions and Diseases in Everyday Infectious Disease Practice—How Experienced Are We?”, *Life*, Vol.12, No. 7: 978, 2022, <https://doi.org/10.3390/life12070978>
- [12] L.S. Alzubaidi, J. Zhang, A.J. Humaidi, A. Al-Dujaili, A. Duan, Y. Al-Shamma, O. Santamaría, J. Fadhel, M. A. Al-Amidie and M.L. Farhan, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions”. *Journal of Big Data*, Vol. 8, No. 1, 2021, <https://doi.org/10.1186/s40537-021-00444-8>.