

## SEGMENTASI LESI KULIT MONKEYPOX MENGGUNAKAN ARSITEKTUR U-NET

Ni Putu Dian Astutik<sup>1§</sup>, IGN Lanang Wijayakusuma<sup>2</sup>

<sup>1</sup>Program Studi Matematika, Universitas Udayana [Email: dianastutik03@gmail.com]

<sup>2</sup>Program Studi Matematika, Universitas Udayana [Email: lanang\_wijaya@unud.ac.id]

<sup>§</sup>Corresponding Author

### ABSTRACT

*Monkeypox has become an issue of global concern as cases continue to rise across various countries. While most cases display mild symptoms, severe infections can lead to life-threatening complications. Early detection is therefore crucial to control the spread of monkeypox, with one approach being the segmentation of monkeypox lesions to differentiate affected areas from healthy skin and remove any interfering elements, such as hair, which can enhance model accuracy. In this consider, due to the inaccessibility of labeled masks, mask information were produced utilizing watershed segmentation with the sobel operator and otsu thresholding. The division of skin injuries was in this way carried out with a U-Net demonstrate, utilizing MobileNetV2 as the backbone and ImageNet weights for transfer learning. The U-Net model reached an accuracy of 88.07%, though some signs of overfitting were observed, likely due to low-quality label information from the watershed labeling process, which necessitates parameter tuning.*

**Keywords:** Monkeypox, CNN, U-Net, Watershed Segmentation

### 1. PENDAHULUAN

Republik Demokratik Kongo menjadi tempat lahirnya virus monkeypox atau cacar monyet, virus ini masih berada dalam satu keluarga dengan virus smallpox. Secara umum gejala yang muncul pada kasus monkeypox terbilang cukup ringan seperti munculnya lesi kulit namun dalam kasus yang serius dengan membawa penyakit tambahan seperti penyakit jantung, gangguan kekebalan tubuh dan HIV, ini dapat mengarahkan ke kasus komplikasi yang serius seperti myocarditis dan penyakit ginjal akut (Thornhill dkk., 2022).

Penggunaan *deep learning* dengan teknik jaringan saraf konvolusi atau *Convolutional Neural Network* (CNN) terutama *model pre-trained* dalam mengekstrak fitur dan melakukan klasifikasi monkeypox dengan virus bertipe pox lainnya memberikan nilai pengukuran kinerja yang lebih memuaskan dibandingkan dengan menggunakan alat klasifikasi tradisional lainnya seperti KNN, SVM, Naive Bayes, *Decision Tree* dan *Random Forest* (Kumar, 2022; Altun dkk., 2023). Dalam kasus monkeypox terdapat beberapa penelitian yang telah melakukan deteksi atau klasifikasi dengan CNN.

Berdasarkan penelitian dari Sahin dkk. (2022); Nayak dkk. (2023); dan Meena dkk. (2024) penggunaan *model pre-trained* yang bervariasi dan telah dilatih pada dataset besar seperti *ImageNet* menjadi pilihan yang baik untuk *transfer learning*. Metode ini efektif dalam mengekstrak fitur citra dari dataset yang terbatas. Selain itu, penerapan *hyperparameter tuning* pada model dapat meningkatkan kinerja klasifikasi virus monkeypox. Hasil dari beberapa penelitian menunjukkan bahwa *MobileNetV2*, *ResNet-18*, dan *InceptionV3* adalah *model pre-trained* yang unggul dalam melakukan klasifikasi monkeypox.

Penelitian lainnya dengan dataset yang berbeda melakukan klasifikasi dengan menambahkan *hyperparameter tuning* mendapatkan hasil terbaik dengan menggunakan *model pre-trained DenseNet201* dan *MobileNetV3-s* (Altun dkk., 2023; Azar dkk., 2023). Ahsan dkk. (2024) melakukan optimasi model dengan SGD dan Adam, diperoleh optimasi dengan Adam menghasilkan kinerja yang lebih baik. Selain itu, diperoleh *model pre-trained* terbaik yang diuji pada jumlah data yang

lebih sedikit adalah M-VGG16 sedangkan M-ResNet-50 memberikan hasil yang lebih unggul dibandingkan M-VGG16 saat diuji pada jumlah data yang lebih banyak.

Kasus-kasus yang disebutkan semuanya adalah kasus klasifikasi virus monkeypox, dengan dataset yang terbatas hal ini menyebabkan kebutuhan untuk menghasilkan analisis yang lebih komprehensif muncul. Maron dkk. (2021) mendemonstrasikan pada kasus klasifikasi lesi kanker kulit diperoleh hasil bahwa meskipun tanpa segmentasi terlebih dahulu algoritma pengklasifikasi dapat membedakannya dengan baik, namun dengan melakukan segmentasi dapat menghilangkan faktor pengganggu seperti rambut yang berada di sekitar area lesi dan akurasi keseluruhan yang lebih tinggi dibandingkan dengan tanpa segmentasi. Ma dkk. (2024) melakukan segmentasi kulit dengan mengusulkan model terbaru yaitu MECTASwin-Unet dan membandingkannya dengan lima model lainnya yaitu FCN, CGNet, U-Net, Trans-Unet, dan Swin-Unet. Model dilatih dengan dataset eksperimental, menariknya dari tiga metrik kinerja yang diukur kinerja U-Net adalah yang terendah dibandingkan metode lainnya, hasil ini mendemonstrasikan ruang perkembangan pada model U-Net.

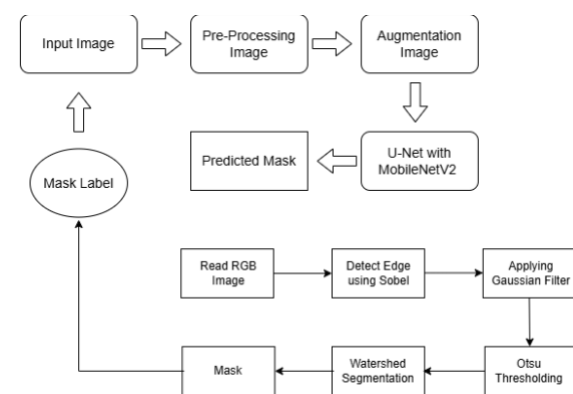
Dalam beberapa tahun terakhir, perkembangan teknik segmentasi citra medis berbasis *deep learning* telah mengalami kemajuan pesat. Salah satu arsitektur yang sering digunakan adalah U-Net. Berdasarkan penelitian Yojana & Rani (2023) arsitektur ini terbukti memberikan kontribusi signifikan dalam meningkatkan akurasi deteksi pada citra medis dibandingkan dengan model lainnya, seperti DeepLabV3+, U-Net menunjukkan performa yang lebih unggul. Penggunaan U-Net dalam segmentasi lesi kulit, telah dilakukan pada citra melanoma pada kanker kulit (ShifaKubra, 2021). Selain itu, U-Net juga diterapkan pada segmentasi citra X-Ray paru-paru dan penerapan pada keduanya menghasilkan performa yang baik (Pranata dkk., 2022). Dalam pembuatan model menggunakan data di bidang medis, keterbatasan data menjadi salah satu tantangan dan penerapan *transfer learning* dan *fine tuning* model pada bagian *encoder* U-Net secara signifikan telah membantu model belajar dengan lebih baik dan meningkatkan akurasi model (Araújo dkk., 2022). Penggunaan *transfer learning* menggunakan model *pre-trained* yang menggunakan konvolusi *depthwise* ringan

seperti MobileNetV2 telah terbukti memberikan kinerja ideal untuk segmentasi citra medis ketika digunakan bersama U-Net (Kanadath dkk., 2021; Wita, 2023)

Menyoroti kesenjangan dalam pemaparan sebelumnya, penelitian ini bertujuan untuk melakukan segmentasi lesi kulit virus monkeypox yaitu memisahkan area lesi dengan kulit sehat serta faktor pengganggu seperti rambut menggunakan arsitektur U-Net serta *transfer learning* pada bagian *encoder* U-Net yang dilatih pada dataset publik yang tersedia menggunakan model *pre-trained* MobileNetV2.

## 2. METODE PENELITIAN

Penelitian ini dilakukan melalui proses berikut:



Gambar 1. Alur Penelitian

### 2.1 Dataset

Dalam penelitian ini digunakan data sekunder yang dapat diakses secara publik di laman Kaggle yaitu Monkeypox Skin Lesion Dataset Version 2.0 (MSLD v2.0). Ali dkk., (2022), (2023) mengembangkan dataset ini dan telah menerima verifikasi dari ahli dermatologi. Dalam dataset ini terdapat data citra lesi kulit monkeypox (284 citra), chickenpox (75 citra), cowpox (66 citra), measles (55 citra), penyakit kulit-kaki-dan mulut (161 citra) dan kulit sehat (114 citra) dengan ukuran 224 x 224 x 3. Pada penelitian ini, 80% citra lesi penyakit monkeypox digunakan sebagai data latih dan 20% sisanya dari citra lesi monkeypox digunakan sebagai data uji.

### 2.2 Pembuatan Label Data

Dalam kasus segmentasi dengan pendekatan *deep learning* diperlukan data citra berupa *mask* dari gambar asli yang berperan sebagai label dari data sehingga memungkinkan

untuk model belajar. Pada dataset yang digunakan tidak terdapat label berupa citra *mask* yang dapat digunakan dalam melakukan segmentasi sehingga akan digunakan teknik *watershed*. Langkah-langkah yang dilakukan adalah sebagai berikut:

### 2.2.1 Operator Sobel

Operator ini digunakan untuk mengekstraksi fitur tepi dari citra dengan cara menerapkan matriks kecil di tiap pixel secara vertikal dan horizontal. Hasil matriks dari arah horizontal disebut gradien x dan hasil matriks dari arah vertikal disebut gradien y. Selanjutnya menghitung magnitudo gradien untuk mendapatkan nilai yang memberikan hasil lebih tinggi pada tepi.

$$\text{Magnitudo} = \sqrt{(\text{grad}_x)^2 + (\text{grad}_y)^2} \quad (1)$$

### 2.2.2 Filter Gaussian

Filter ini digunakan dalam menambah keburaman pada citra sehingga dapat mengurangi *noise* dan detail kecil, serta menghaluskan citra. Proses ini dilakukan dengan menerapkan *kernel* Gaussian, yang memberikan bobot lebih besar pada pixel yang berada di sekitar pusat, sehingga menghasilkan transisi yang lebih halus pada tepi citra

### 2.2.3 Thresholding Otsu

*Thresholding* Otsu digunakan untuk menentukan nilai ambang (*threshold*) yang optimal untuk memisahkan objek dari latar belakang dalam citra. Dengan menggunakan varians dalam citra, *thresholding* ini mengidentifikasi nilai ambang yang meminimalkan intra-kelas varians, sehingga meningkatkan segmentasi citra.

### 2.2.4 Segmentasi Watershed

Metode ini memperlakukan citra sebagai topografi, di mana intensitas pixel diinterpretasikan sebagai ketinggian. Dengan menggunakan informasi dari hasil *thresholding* otsu dan operasi sebelumnya, segmentasi *watershed* dapat mengidentifikasi daerah terpisah berdasarkan kontur yang dihasilkan, sehingga memungkinkan untuk menghasilkan *mask* yang akurat untuk setiap objek dalam citra.

## 2.3 Pra-Pemrosesan Data

Dalam pra-pemrosesan data ini dilakukan penyeragaman ukuran gambar ke ukuran 224 x 224 dan normalisasi skala citra dengan mengubahnya menjadi skala [0, 1], normalisasi dilakukan menggunakan pendekatan *min-max*. Dengan pendekatan ini nilai normalisasi adalah hasil pembagian antara selisih nilai pixel asli

dengan nilai pixel terkecil dengan selisih nilai pixel terkecil dan terbesar.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2)$$

## 2.4 Augmentasi Data

Augmentasi data dilakukan untuk menambah variabilitas data yang disebabkan oleh jumlah dataset yang terbatas. Kegiatan ini meliputi rotasi, pergeseran rotasi secara vertikal dan horizontal, distorsi miring (*shear*), dan memutar gambar (*flip*) secara vertikal dan horizontal. Dengan bantuan augmentasi data model dapat melakukan generalisasi dengan lebih baik tanpa mengubah label citra.

## 2.5 Ekstraksi Fitur

### 2.5.1 Convolutional Neural Network (CNN)

Pendekatan *machine learning* saat ini banyak digunakan dalam melakukan berbagai analisis mendalam dan salah satu bagian *machine learning* yang saat ini sedang trending adalah penggunaan *deep learning* yaitu CNN. Dalam bidang medis CNN banyak digunakan untuk melakukan pemrosesan citra karena kemampuannya dalam mengekstraksi fitur yang representatif dengan baik menggunakan lapisan konvolusi, bagian ini sangat berperan penting dalam mengidentifikasi fitur yang representatif karena dalam konstruksinya juga ditambahkan fungsi aktivasi non-linear yang berguna dalam menangkap fitur kompleks dalam citra (Kshatri & Singh, 2023).

### 2.5.2 U-Net

U-Net merupakan arsitektur berbentuk simetris (bentuk U) yang umum digunakan dalam melakukan segmentasi citra medis. U-Net dikembangkan pada tahun 2015 yang terdiri dari tiga bagian yaitu bagian *encoder*, *decoder*, dan *skip connection*. Bagian *encoder* berfungsi untuk mengekstraksi fitur dari citra yang di input dan pada U-Net bagian ini memiliki empat blok utama. Selanjutnya bagian *decoder* berfungsi untuk menyusun ulang kembali gambar dengan memperbesar resolusi fitur dan menambahkannya dengan fitur dari *skip connection*, bagian *decoder* ini memiliki empat blok utama sama seperti bagian *encoder*. *Skip connection* adalah jalur yang menghubungkan bagian *encoder* dan *decoder* pada tingkat resolusi yang sama yang bertujuan untuk mempertahankan informasi spasial sehingga segmentasi yang dihasilkan lebih akurat (Yin dkk., 2022).


### 2.5.2 Backbone

*Backbone* merupakan istilah yang digunakan dalam merujuk jaringan yang digunakan pada bagian *encoder* pada arsitektur U-Net dalam mengekstraksi fitur. Penggunaan model *pre-trained* lazim digunakan dalam mengatasi keterbatasan data. Dalam penelitian ini digunakan model *pre-trained* MobileNetV2 dengan menggunakan bobot dari *ImageNet* sebagai bagian dari *transfer learning*.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Segmentasi Watershed

Pembuatan citra *mask* sebagai label dilakukan dengan menggunakan teknik *watershed* dengan deteksi tepi menggunakan operator sobel menghasilkan 284 citra *mask*. Namun, dari hasil segmentasi ini terdapat citra yang tidak tersegmentasi dengan baik. Berikut adalah beberapa kesalahan segmentasi pada citra.




Gambar 2. Kesalahan Segmentasi 1

Gambar 2 menunjukkan *mask* yang dihasilkan memberikan hasil segmentasi lokasi lesi yang salah. Contoh lain terdapat citra dengan banyak lesi yang berdekatan dan hasil segmentasinya tidak dapat memisahkan area kulit sehat di antara lesi yang berdekatan, berikut adalah contohnya.



Gambar 3. Kesalahan Segmentasi 2

Pada gambar 3 terlihat bahwa hasil segmentasi yang dihasilkan cukup kasar dan tidak detail namun dapat mengenali lokasi lesi dengan tepat. Selain menghasilkan segmentasi yang salah terdapat juga segmentasi yang tepat, sebagai berikut.




Gambar 4. Tersegmentasi dengan benar

Dapat dilihat pada gambar 4 bahwa citra yang dapat tersegmentasi dengan baik adalah citra yang memiliki kualitas yang jernih, tidak memiliki banyak variasi visual seperti lekukan tubuh, simbol atau teks pada citra dan minim faktor pengganggu seperti rambut, tangan, simbol, dan lain-lainnya di sekitar lesi. Selain itu, untuk memperoleh hasil segmentasi yang baik diperlukan *tuning* parameter seperti ukuran *kernel* dan ukuran *thresholding* namun penyesuaian parameter ini mungkin tidak bisa berlaku ke semua citra mengingat beberapa citra memiliki variasi yang lebih banyak.

### 3.2 U-Net

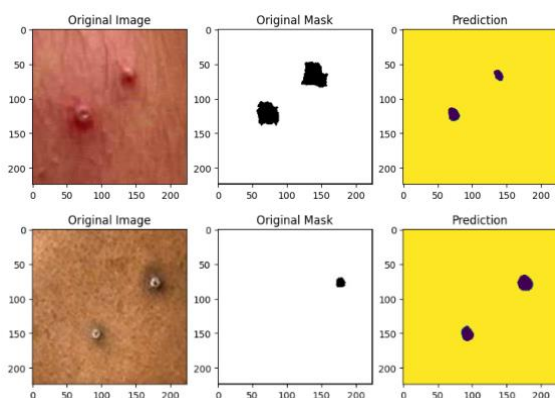
Pelatihan model menggunakan arsitektur U-Net dengan *backbone* MobileNetV2 dan mengambil menggunakan bobot *ImageNet* sebagai *transfer learning*. Data dibagi dalam *batch* berukuran 16, dan pelatihan dijalankan selama 50 *epoch* menggunakan fungsi *loss Dice* dan fungsi optimasi Adam dengan *learning rate* awal sebesar 0.001. Selama proses pelatihan *callback ReduceLROnPlateau* yang memonitor variabel '*val\_loss*' dengan tingkat kesabaran 5 *epoch*, menyebabkan pelatihan dihentikan pada *epoch* ke-17, dan *learning rate* disesuaikan menjadi 5.0000e-04. Selain *callback* tersebut, penulis juga menggunakan *EarlyStopping* yang memonitor variabel '*val\_accuracy*' pada tingkat kesabaran 10 *epoch*. Augmentasi data dilakukan menggunakan *ImageDataGenerator* dari Keras, dengan jumlah yang dihasilkan saat dilatih hingga 17 *epoch* sebanyak 4409 citra. Setelah proses pelatihan selesai diperoleh tingkat akurasi

sebesar 88.07%, berikut adalah hasil akurasi dan *loss* model secara keseluruhan.



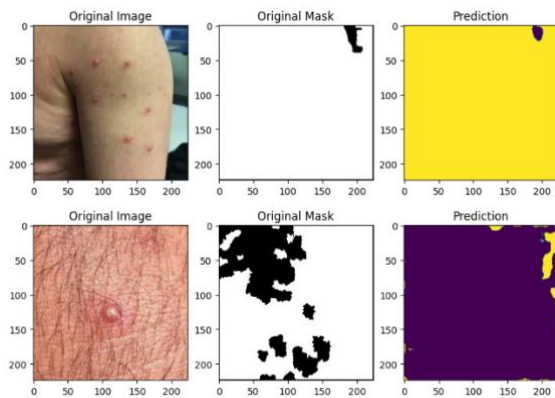
Gambar 5. Akurasi dan *Loss* Model

Terlihat peningkatan akurasi pada data pelatihan meningkat dengan stabil, namun akurasi pada data validasi terlihat tidak stabil di beberapa *epoch* pertama dan terakhir. Sedangkan pada model *loss* penurunan *loss* data pelatihan dan data validasi konvergen menuju nol walaupun pada *epoch* ke-14 terjadi peningkatan *loss* data validasi, namun secara umum model *loss* terlihat stabil. Meskipun model *loss* memberikan performa yang stabil namun melihat performa akurasi model pada beberapa *epoch* tidak stabil ini menjadi tanda model *overfitting*. Selanjutnya hasil prediksi pada beberapa data uji memberikan beberapa kondisi sebagai berikut.




Gambar 6. Kondisi Pertama

Pertama, model dapat memprediksi hasil *mask* dengan tepat terlepas label *mask* mencerminkan area lesi dengan benar saat citra asli hanya memfokuskan pada area lesi dan minim faktor pengganggu seperti rambut dan tangan, seperti contoh yang ditampilkan pada gambar 6.



Gambar 7. Kondisi Kedua

Kedua, saat citra memiliki banyak faktor pengganggu dan tidak fokus pada area lesi model cenderung menghasilkan prediksi yang tidak tepat dan mengikuti label *mask*.



Gambar 8. Kondisi Ketiga

Ketiga, model gagal memprediksi area lesi seperti gambar 8 hal ini mungkin disebabkan oleh *overfitting*, kualitas citra yang memiliki banyak noise, kualitas label *mask* yang buruk akibat kesalahan area segmentasi sehingga mengurangi kemampuan model dalam mempelajari pola yang benar, dan keterbatasan dataset mengingat jumlah citra lesi monkeypox hanya 284 citra. Dalam proses pembuatan kode model U-Net ini penulis menggunakan beberapa referensi dari sumber berikut ini (Dorltcheng, 2021).

#### 4. KESIMPULAN DAN SARAN

Dalam mengatasi keterbatasan data label (*mask*) pada kasus segmentasi lesi kulit monkeypox digunakan teknik segmentasi *watershed*. Namun, kualitas *mask* yang dihasilkan cukup buruk karena terdapat banyak *mask* yang gagal disegmentasi pada area yang tepat. Hal ini kemungkinan dikarenakan kurangnya *tuning* parameter dan kualitas citra asli yang kurang baik seperti banyak faktor pengganggu dan citra tidak memfokuskan ke area lesi saja. Selanjutnya, hasil yang diberikan oleh model U-Net dengan *backbone* MobileNetV2 menghasilkan akurasi 88.07% dengan model terindikasi memiliki *overfitting*

dan kemampuan model melakukan prediksi area lesi masih perlu ditingkatkan, hal ini mungkin diakibatkan oleh keterbatasan dataset dan kualitas label *mask* yang buruk.

Dalam meningkatkan kualitas penelitian selanjutnya, berikut adalah saran penelitian yang dapat diberikan oleh penulis:

- a. Meningkatkan kualitas label (*mask*) dengan melakukan *tuning* parameter pada segmentasi *watershed* atau melakukan pelabelan data menggunakan metode lainnya.
- b. Menghilangkan indikasi overfitting pada model U-Net dengan melakukan *tuning hyperparameter* atau menggunakan teknik lainnya.

## DAFTAR PUSTAKA

- Ahsan, M. M., Alam, T. E., Haque, M. A., Ali, M. S., Rifat, R. H., Nafi, A. A. N., Hossain, M. M., & Islam, M. K. (2024). Enhancing Monkeypox diagnosis and explanation through modified transfer learning, vision transformers, and federated learning. *Informatics in Medicine Unlocked*, 45. <https://doi.org/10.1016/j.imu.2024.101449>
- Ali, S. N., Ahmed, Md. T., Jahan, T., Paul, J., Sani, S. M. S., Noor, N., Asma, A. N., & Hasan, T. (2023). A Web-based Mpox Skin Lesion Detection System Using State-of-the-art Deep Learning Models Considering Racial Diversity. <https://doi.org/10.48550/arXiv.2306.14169>
- Ali, S. N., Ahmed, Md. T., Paul, J., Jahan, T., Sani, S. M. S., Noor, N., & Hasan, T. (2022). Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study. <http://arxiv.org/abs/2207.03342>
- Altun, M., Gürüler, H., Özkaraca, O., Khan, F., Khan, J., & Lee, Y. (2023a). Monkeypox Detection Using CNN with Transfer Learning. *Sensors*, 23(4). <https://doi.org/10.3390/s23041783>
- Araújo, R. L., Araújo, F. H. D. de, & Silva, R. R. V. e. (2022). Automatic segmentation of melanoma skin cancer using transfer learning and fine-tuning. *Multimedia Systems*, 28, 1239–1250. <https://doi.org/10.1007/s00530-021-00840-3>
- Azar, A. S., Naemi, A., Rikan, S. B., Mohasefi, J. B., Pirnejad, H., & Wiil, U. K. (2023). Monkeypox detection using deep neural networks. *BMC Infectious Diseases*, 23. <https://doi.org/10.1186/s12879-023-08408-4>
- Dorltcheng. (2021). *Transfer Learning U-Net Deep Learning For Lung Ultrasound Segmentation*. <https://github.com/dorltcheng/Transfer-Learning-U-Net-Deep-Learning-for-Lung-Ultrasound-Segmentation>.
- Kanadath, A., Jothi, J. A. A., & Urolagin, S. (2021). Histopathology Image Segmentation Using MobileNetV2 based U-net Model. *2021 International Conference on Intelligent Technologies (CONIT)*, 1–8. <https://doi.org/10.1109/CONIT51480.2021.9498341>
- Kshatri, S. S., & Singh, D. (2023). Convolutional Neural Network in Medical Image Analysis: A Review. *Archives of Computational Methods in Engineering*, 30(4), 2793–2810. <https://doi.org/10.1007/s11831-023-09898-w>
- Kumar, V. (2022). Analysis of CNN features with multiple machine learning classifiers in diagnosis of monkeypox from digital skin images. *medRxiv*, 2022.09.11.22278797. <https://doi.org/10.1101/2022.09.11.22278797>
- Ma, J. F., He, P. F., Li, C. L., & Nie, R. (2024). Mpox Virus Image Segmentation Based on Multiscale Expansion Convolution. *IEEE Access*, 12, 117608–117616. <https://doi.org/10.1109/ACCESS.2024.3448364>
- Maron, R. C., Hekler, A., Krieghoff-Henning, E., Schmitt, M., Schlager, J. G., Utikal, J. S., & Brinker, T. J. (2021). Reducing the Impact of Confounding Factors on Skin Cancer Classification via Image Segmentation: Technical Model Study. *Journal of Medical Internet Research*, 23(3), e21695. <https://doi.org/10.2196/21695>

- Meena, G., Mohbey, K. K., & Kumar, S. (2024). Monkeypox recognition and prediction from visuals using deep transfer learning-based neural networks. *Multimedia Tools and Applications*, 83(28), 71695–71719. <https://doi.org/10.1007/s11042-024-18437-z>
- Nayak, T., Chadaga, K., Sampathila, N., Mayrose, H., Gokulkrishnan, N., Bairy G, M., Prabhu, S., S, S. K., & Umakanth, S. (2023). Deep learning based detection of monkeypox virus using skin lesion images. *Medicine in Novel Technology and Devices*, 18. <https://doi.org/10.1016/j.medntd.2023.100243>
- Pranata, T., Desiani, A., Suprihatin, B., Hanum, H., & Efriliyanti, F. (2022). Segmentation of the Lungs on X-Ray Thorax Image with CNN Architecture U-Net. *Computer Engineering and Applications*, 11(2). <https://www.kaggle.com/nikhilpandey360/chest-xray-masks-and-labels>.
- Sahin, V. H., Oztel, I., & Yolcu Oztel, G. (2022). Human Monkeypox Classification from Skin Lesion Images with Deep Pre-trained Network using Mobile Application. *Journal of Medical Systems*, 46. <https://doi.org/10.1007/s10916-022-01863-7>
- ShifaKubra, N. (2021). Skin Cancer Segmentation Using U-Net. *International Journal for Research in Applied Science and Engineering Technology*. <https://api.semanticscholar.org/CorpusID:238695693>
- Thornhill, J. P., Barkati, S., Walmsley, S., Rockstroh, J., Antinori, A., Harrison, L. B., Palich, R., Nori, A., Reeves, I., Habibi, M. S., Apea, V., Boesecke, C., Vandekerckhove, L., Yakubovskiy, M., Sendagorta, E., Blanco, J. L., Florence, E., Moschese, D., Maltez, F. M., ... Orkin, C. M. (2022). Monkeypox Virus Infection in Humans across 16 Countries — April–June 2022. *New England Journal of Medicine*, 387(8), 679–691. <https://doi.org/10.1056/nejmoa2207323>
- Wita, D. S. (2023). Image Segmentation of Normal Pap Smear Thinprep using U-Net with Mobilenetv2 Encoder. *Journal Medical Informatics Technology*. <https://api.semanticscholar.org/CorpusID:260648237>
- Yin, X. X., Sun, L., Fu, Y., Lu, R., & Zhang, Y. (2022). U-Net-Based Medical Image Segmentation. Dalam *Journal of Healthcare Engineering* (Vol. 2022). <https://doi.org/10.1155/2022/4189781>
- Yojana, K., & Rani, L. T. (2023). OCT layer segmentation using U-NET semantic segmentation and RESNET34 encoder-decoder. *Measurement: Sensors*, 29. <https://doi.org/10.1016/j.measen.2023.100817>