

## PENERAPAN BLOK SE-NET PADA DEEP LEARNING INCEPTIONV3 UNTUK MENINGKATKAN DETEKSI PENYAKIT MPOX PADA MANUSIA

M. Bakhara Alief Rachman<sup>\*1</sup>, Aliyah Kurniasih<sup>2</sup>, Andika Sundawijaya<sup>3</sup>, Ahlijati Nuraminah<sup>4</sup>

<sup>1,2,3,4</sup>Sekolah Tinggi Ilmu Manajemen & Ilmu Komputer ESQ, Jakarta  
Email: <sup>1</sup>m.bakhara.a.r@students.esqbs.ac.id, <sup>2</sup>aliyah.kurniasih@esqbs.ac.id,  
<sup>3</sup>andika.sundawijaya@esqbs.ac.id, <sup>4</sup>ahlijati.nuraminah@esqbs.ac.id  
<sup>\*</sup>Penulis Korespondensi

(Naskah masuk: 07 November, diterima untuk diterbitkan: 30 Oktober 2024)

### Abstrak

*Mpox* atau cacar monyet adalah penyakit yang disebabkan oleh virus *monkeypox*. Penelitian terdahulu membuktikan sudah tersedia beberapa *pre-trained* model yang terbukti mampu mendeteksi penyakit *mpox* dengan menggunakan dataset MSLD (*Monkeypox Skin Lesion Dataset*) seperti VGG16, ResNet50, InceptionV3, dan penggabungan ketiga model tersebut. Dari penelitian tersebut didapatkan hasil model InceptionV3 memiliki tingkat akurasi paling rendah dengan nilai 74.07% berbanding jauh dengan ResNet50 yang mampu hingga 82.96% dan menjadikannya akurasi tertinggi. Namun, terdapat peluang akurasi model InceptionV3 mampu ditingkatkan. Oleh sebab itu, pada penelitian diimplementasikan arsitektur baru dan penambahan blok SE-Net (*Squeeze and Excitation Networks*) pada *pre-trained* model InceptionV3. Untuk *training* dan *evaluasi* model akan menggunakan dataset MSLD. Penelitian ini dilaksanakan dengan harapan mampu meningkatkan akurasi *pre-trained* model InceptionV3 dalam mendeteksi penyakit *mpox*. Dari hasil penelitian berdasarkan nilai *confusion matrix* penerapan arsitektur baru berhasil dilakukan terbukti dengan peningkatan akurasi dari 74.07% menjadi 82.22%. Selain itu, penambahan blok SE-Net terhadap arsitektur baru terbukti mampu meningkatkan akurasi menjadi 91.11% dan menjadikan performa InceptionV3 menjadi lebih baik dari akurasi ResNet50. Dari hasil penelitian tersebut memberikan rekomendasi untuk melakukan percobaan dengan mengganti *pre-trained* model, blok SE-Net, dan jumlah perbandingan dataset antara *train*, *validation*, dan *test*.

**Kata kunci:** *Mpox*, MSLD (*Monkeypox Skin Lesion Dataset*), CNN (*Convolutional Neural Network*), InceptionV3, SE-Net

## SE-NET BLOCK APPLICATION IN DEEP LEARNING INCEPTIONV3 TO IMPROVE MPOX DISEASE DETECTION IN HUMANS

### Abstract

*Mpox* or monkeypox is a disease caused by the monkeypox virus. Previous research has proven that there are several *pre-trained* models that are proven to be able to detect *mpox* disease using MSLD (*Monkeypox Skin Lesion Dataset*) datasets such as VGG16, ResNet50, InceptionV3, and a combination of these three models. From this research, it was found that the InceptionV3 model has the lowest level of accuracy with a value of 74.07% compared to ResNet50 which is capable of up to 82.96% and makes it the highest accuracy. However, there is a chance that accuracy can be improved. Therefore, this research will apply a new architecture and SE-Net blocks to the InceptionV3 *pre-trained* model using the MSLD dataset. From the results of research based on the value of the *confusion matrix* the application of the new architecture was successfully carried out as evidenced by an increase in accuracy from 74.07% to 82.22%. In addition, the addition of the SE-Net block to the new architecture is proven to be able to increase accuracy to 91.11% and make InceptionV3's performance better than ResNet50's accuracy. The results of this study provide recommendations for conducting experiments by changing the *pre-trained* model, the SE-Net block, and the number of dataset comparisons between *train*, *validation*, and *test*.

**Keywords:** *Mpox*, MSLD (*Monkeypox Skin Lesion Dataset*), CNN (*Convolutional Neural Network*), InceptionV3, SE-Net

### 1. PENDAHULUAN

*Mpox* adalah penyakit yang disebabkan oleh virus *monkeypox* [1]. *Mpox* adalah infeksi *zoonosis*

virus, yang berarti virus mampu untuk menyebar dari hewan ke manusia, manusia ke manusia, atau lingkungan ke manusia [2]. Virus *monkeypox* pertama

kali ditemukan pada seekor monyet di Denmark pada tahun 1958 [3]. Kemudian pada tahun 1950 seorang anak berumur sembilan bulan di Republik Demokratik Kongo teridentifikasi terdapat virus *monkeypox* di dalam tubuhnya. Kasus ini menjadikan pertama kalinya virus *monkeypox* ditemukan pada tubuh manusia (WHO, 2022b).

Pada tahun 2017, *mpox* kembali muncul di Nigeria dan terus menyebar ke berbagai negara [2]. Kasus *mpox* sempat menurun sampai akhirnya muncul kembali di Inggris pada awal Mei 2022 [4]. Kasus ini muncul secara tiba – tiba dan menyebar dengan begitu cepatnya di Eropa, Amerika, dan keenam wilayah WHO (semua benua). kurang lebih terdapat 110 negara dan 87 ribu kasus ditemukan dengan kasus kematian mencapai 112 kasus (WHO, 2022a).

Pada tahun 2022, Ali et al., dalam penelitiannya mengemukakan bahwa pendeteksian awal, melacak kontak penyebaran, dan isolasi penderita penyakit *mpox* begitu penting untuk membatasi penyebaran virus di komunitas. Namun, mengidentifikasi *mpox* bisa begitu sulit karena kemiripan dengan infeksi penyakit lain [4]. Oleh sebab itu begitu penting untuk membedakan *mpox* dengan *chickenpox*, *measles*, bakteri yang menyerang kulit, dan penyakit yang berkaitan dengan alergi. Standar terbaik untuk mendiagnosa penyakit *mpox* adalah dengan *histopathology* (prosedur yang melibatkan pemeriksaan jaringan utuh yang diambil melalui biopsi atau operasi di bawah mikroskop) dan isolasi virus (proses pemisahan dan identifikasi virus dari sampel biologis, seperti jaringan tubuh, darah, atau sekresi yang mungkin mengandung virus) [6]. Sebagai tambahan, PCR (*polymerase chain reaction*) bisa membantu untuk mengkonfirmasi diagnosis tersebut.

Ketika alat untuk mendiagnosa ini belum tersedia secara mudah, diagnosa awal dengan melihat lesi kulit dengan bantuan AI (*artificial intelligence*) mampu memberikan beberapa manfaat dan dapat dijadikan sebagai sebuah jembatan antar gap di sistem kesehatan [5]. Salah satu bentuk AI yang dapat kita andalkan adalah *deep learning*. *Deep learning* merupakan bagian dari *machine learning* [7]. Teknologi *deep learning* dianggap sebagai salah satu topik hangat dalam bidang *machine learning*, kecerdasan buatan serta ilmu data dan analitik, karena itu kemampuan belajar dari data yang diberikan [8]. Banyak perusahaan termasuk Google, Microsoft, Nokia, dll., Mempelajari secara aktif karena dapat memberikan hasil yang signifikan dalam berbagai masalah klasifikasi dan regresi [9].

Saat ini sudah tersedia banyak *pre-trained* model yang terbukti mampu untuk mendeteksi *mpox* dengan menggunakan *dataset* yang berasal dari MSLD (*Monkeypox Skin Lesion Dataset*) seperti VGG16, ResNet50, InceptionV3, dan penggabungan ketiga model tersebut [5]. Keempat *pre-trained* model tersebut terbukti andal dalam mendeteksi *mpox*

karena tersusun akan banyak layer CNN (*Convolutional Neural Network*) yang secara desain memang ditujukan untuk objek berbasis citra. Namun dengan arsitektur yang mereka gunakan, model InceptionV3 memiliki tingkat akurasi paling rendah ketika dilakukan evaluasi. Untuk akurasi InceptionV3 hanya di angka 74.07% berbanding jauh dengan ResNet50 yang mampu hingga 82.96% dan menjadikannya akurasi tertinggi.

InceptionV3 adalah model pengenalan gambar yang telah terbukti mencapai akurasi lebih dari 78,1% pada kumpulan data ImageNet (Szegedy et al., 2016). Model ini merupakan puncak dari banyak ide yang dikembangkan oleh banyak peneliti selama bertahun-tahun. Ini didasarkan pada makalah asli: "Rethinking the Inception Architecture for Computer Vision". InceptionV3 adalah hasil pengembangan dari InceptionV1 yang saat pertama kali diperkenalkan bernama GoogLeNet pada tahun 2014 (Google, 2023) Model itu sendiri terdiri dari blok bangunan simetris dan asimetris, termasuk *layer convolutions*, *average pooling*, *max pooling*, *concatenations*, *dropouts*, and *fully connected (dense)*.

Hu, Shen and Sun (2018) merancang blok SE-Net (SE-Net atau Squeeze and Excitation Networks) yang memiliki tujuan untuk meningkatkan kualitas dari model yang berbasis CNN. Blok SE-Net memiliki mekanisme untuk melakukan kalibrasi ulang fitur dengan cara mempelajari informasi yang ada untuk secara selektif menekan fitur – fitur informasi yang dianggap tidak penting.

Penggunaan SE-Net pada InceptionV3 sudah pernah diterapkan sebelumnya (Ye and Toyama, 2021), namun penerapannya untuk mendeteksi penyakit *mpox* perlu diteliti lebih lanjut untuk mendapatkan tingkat akurasi yang lebih baik. Oleh karena itu, penelitian ini akan mengimplementasikan arsitektur baru dan menambahkan blok SE-Net (Squeeze and Excitation Networks) pada *pre-trained* model InceptionV3. Untuk *training* dan *evaluasi* model akan menggunakan dataset MSLD. Penelitian ini dilaksanakan dengan harapan mampu meningkatkan akurasi *pre-trained* model InceptionV3 dalam mendeteksi penyakit *mpox*.

## 2. METODE PENELITIAN

Tahapan penelitian yang dilakukan terdiri dari lima tahap, pengambilan dan pembagian dataset, *pre-processing*, inialisasi arsitektur model, pelatihan (*training*) model, dan evaluasi model.

### 2.1 Pengumpulan dan Pembagian Dataset

Pada penelitian ini dataset yang digunakan berasal dari MSLD (*Monkeypox Skin Lesion Dataset*) (Kaggle, 2023). Karakteristik yang terdapat pada dataset terdiri dari dua macam jenis citra yang terdiri dari *Monkeypox (mpox)* dan *Others (chickenpox and measles)*. Setelah itu, dilakukan pembagian dataset menjadi tiga bagian yaitu *train*,

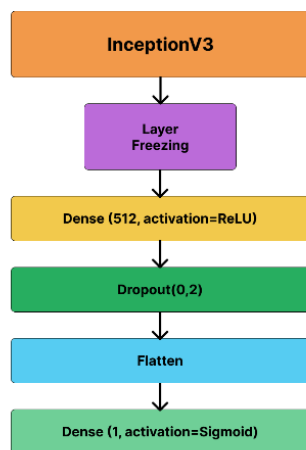
*validation*, dan *test* dengan porsi 70:10:20. Setelah itu, *dataset train* dan *validation* dilakukan augmentasi yang didalamnya terdapat beberapa metode seperti *rotation*, *translation*, *reflection*, *shear*, *hue*, *saturation*, *contrast* dan *brightness jitter*, *noise*, dan *scaling*. Hal ini dilakukan untuk memperbanyak data yang nantinya akan digunakan untuk *training*. Akibat proses augmentasi, membuat jumlah dataset menjadi bertambah. Jumlah citra *monkeypox* yang sebelumnya 102 menjadi 1.168 dan citra *others* yang sebelumnya 126 menjadi 1.439.

## 2.2 Preprocessing

Selanjutnya *dataset* akan melakukan proses *pre-processing*. Tahap *pre-processing* diawali dengan normalisasi. Normalisasi dilakukan agar proses *training* dan evaluasi model menjadi lebih mudah serta meningkatkan kestabilan dan konvergensi terutama pada proses *training*. Setelah dilakukan normalisasi, *dataset* akan masuk ke tahap penentuan ukuran citra, labelling, dan penentuan batch size. Pada penelitian ini akan menggunakan ukuran 224 x 224 dengan tipe label *binary*. Kemudian *batch size* akan berada di angka 16.

## 2.3 Inisialisasi Arsitektur Model

Pada tahap ini akan dilakukan perancangan model. Nantinya akan ada dua rancangan yang dibuat. Yaitu pre-trained model *InceptionV3* tanpa dan dengan blok *SE-Net*. Hal tersebut dilakukan untuk melihat pengaruh blok *SE-Net* dalam meningkatkan akurasi rancangan arsitektur yang dibuat.

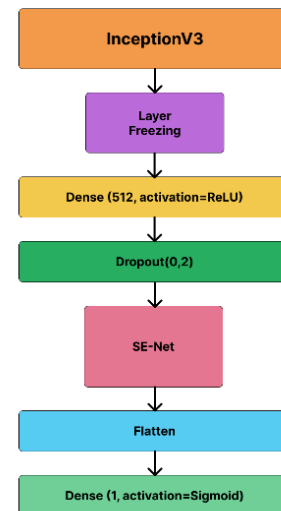


Gambar 1. Arsitektur tanpa Blok *Se-Net*

Seperti yang terlihat pada Gambar 1, rancangan diawali dengan menggunakan pre-trained model *InceptionV3*. Setelah itu, dilakukan *fine-tuning* dengan meng-freeze semua layer, kecuali tiga layer terakhir pada *InceptionV3*. *Fine-tuning* umum dilakukan dalam menyusun sebuah model karena dengan metode ini model dapat memiliki kemampuan ekstraksi citra yang baik karena sebelumnya sudah dilatih dengan *dataset* yang jumlahnya besar, tetapi

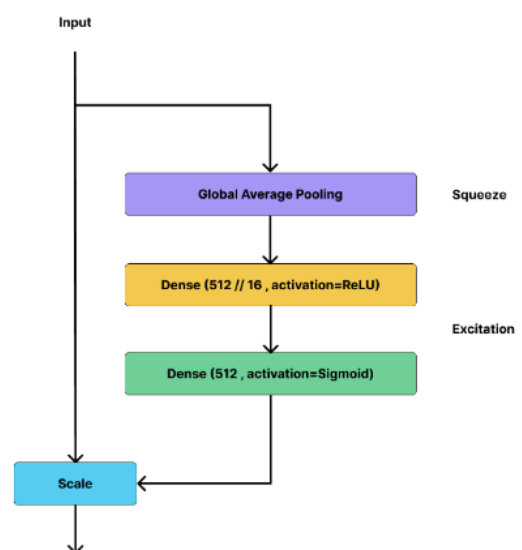
memiliki kemampuan klasifikasi yang disesuaikan dengan output yang peneliti inginkan.

Selanjutnya, ditambahkan *connected* atau *dense layer* dengan *activation ReLU*. Pemilihan layer tersebut bertujuan untuk meningkatkan kompleksitas model dalam mempelajari *dataset*. Selanjutnya, ditambahkan *dropout layer* untuk mencegah *overfitting* dan *flatten layer* untuk menghubungkan output dari *dropout layer* ke *dense layer* dengan node 1 (satu) dan *activation Sigmoid*. Pemilihan jumlah node 1 (satu) dan *activation Sigmoid* karena output yang diinginkan bersifat *binary*.



Gambar 2. Arsitektur dengan Blok *Se-Net*

Seperti yang terlihat pada Gambar 2, tidak ada perbedaan dalam penyusunan layer, kecuali penambahan blok *SE-Net* diantara *dropout layer* dan *flatten layer*.



Gambar 3. Layer yang menyusun Blok *SE-Net*

Pada Gambar 3, terlihat blok *SE-Net* memiliki beberapa layer yang berfungsi untuk menjalankan dua proses. Yaitu, *squeeze* dan *excitation*. Untuk

proses *squeeze*, dilakukan oleh *GlobalAveragePooling*. Proses ini akan mengekstraksi informasi dari input dan mengambil rata – rata nilai dari setiap *node* pada input.

Proses selanjutnya, *excitation* akan dilakukan oleh dua buah *dense layer* yang dengan dua *activation* yang berbeda. Untuk *dense layer* dengan *activation ReLU* bertujuan untuk menentukan *weight* yang optimal untuk setiap *node*, setelah itu *dense layer* dengan *activation Sigmoid* akan menghasilkan *weight* antara 0 (nol) hingga 1 (satu) sebagai gambaran bahwa *node* ini dipertahankan atau tidak. Setelah menentukan *node* mana saja yang penting atau tidak, proses terakhir adalah proses perkalian pada input dengan *scale*. Dengan perkalian di setiap *node* pada input yang diberikan bertujuan untuk memberikan penekanan kepada *node* mana yang penting atau tidak.

Tahap terakhir dalam merancang arsitektur model, kedua arsitektur ini akan di-*compile* dengan *optimizer* Adam. Lalu, untuk *loss function* yang digunakan adalah *binary\_crossentropy* karena output model yang berbentuk *binary* dan metrik yang digunakan adalah *accuracy*.

## 2.4 Pelatihan (Training) Model

Terdapat dua fungsi *callback* yang digunakan dalam proses *training* model. Yaitu, *LearningRateScheduler* dan *ModelCheckpoint*. *LearningRateScheduler* digunakan untuk mengatur penurunan *learning rate* secara otomatis selama proses *training* berlangsung dan *ModelCheckpoint* digunakan untuk mengambil model terbaik selama *training* model. Dimana penentuan model terbaik dilihat dari nilai *validation loss* terkecil. Pada tahap ini akan dilihat performa *training* model ketika dilatih dengan data *train* dan data *validation*.

Tabel 1. Hasil Model Terbaik pada Tahap Training Model

Arsitektur	Loss	Accuracy	Validation n loss	Validation Accuracy
tanpa SE	0,3881	0,8427	0,6944	0,7071
dengan SE	0,4136	0,8198	0,6134	0,7476

Berdasarkan Tabel 1, ketika dilakukan training model pada masing-masing arsitektur, didapatkan bahwa model terbaik tanpa *SE-Net* mendapatkan nilai *loss* 0,3881, *accuracy* 0,8428, *validation loss* 0,6944, dan *validation accuracy* 0,7071, pada saat nilai epoch ke-1 dari 15 epoch yang telah didefinisikan, dengan nilai *learning rate* 0,001. Pada model terbaik dengan *SE-Net* mendapatkan nilai *loss* 0,4136, *accuracy* 0,8427, *validation loss* 0,6134, dan *validation accuracy* 0,7476, pada saat nilai epoch ke-1 dari 15 epoch yang telah di definisikan, dengan nilai *learning rate* 0,001.

Namun, hasil *training* model tersebut belum menunjukkan kemampuan model sebenarnya dalam mengeneralisasi data. Oleh sebab itu, model akan melakukan tahap evaluasi dengan data *test* yang di dalamnya terdapat citra asli yang sama sekali belum dikenali model.

## 3. HASIL DAN PEMBAHASAN

Evaluasi performa model menggunakan data *test* yang sebelumnya tidak dilibatkan dalam *training* model sehingga model benar – benar mendeteksi gambar yang baru dikenali. Evaluasi model dengan melihat hasil model berdasarkan *matrix performance* yaitu *confusion matrix*. Dari nilai yang dihasilkan pada tabel *confusion matrix* maka akan dihitung untuk mencari nilai *accuracy*, *precision*, *recall*, dan *F1 Score* (Bajaj and Sinha, 2022).

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

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

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

$$F1\ score = \frac{2*precision*recall}{precision+recall} \quad (4)$$

Tabel 2 merupakan hasil evaluasi model menggunakan *confusion matrix* untuk kedua konsep model arsitektur.

Tabel 2. Hasil Confusion Matrix

Arsitektur	TP	TN	FP	FN
tanpa SE	19	18	1	7
dengan SE	19	22	1	3

Berdasarkan Tabel 2, hasil menunjukan bahwa model terbaik tanpa *SE-Net* mampu mendeteksi citra dengan penyakit *mpox* dengan benar atau TP (*True Positive*) sebanyak 19 dan citra dengan penyakit *others* dengan benar atau TN (*True Negative*) sebanyak 18. Lalu, model salah dalam mendeteksi citra dengan penyakit *mpox* atau FP (*False Positive*) sebanyak 1 (satu) dan salah dalam mendeteksi citra dengan penyakit *others* atau FN (*False Negative*) sebanyak 7 (tiga).

Sementara, model terbaik dengan *SE-Net* mampu mendeteksi citra dengan penyakit *mpox* dengan benar atau TP (*True Positive*) sebanyak 19 dan citra dengan penyakit *others* dengan benar atau TN (*True Negative*) sebanyak 22. Lalu, model salah dalam mendeteksi citra dengan penyakit *mpox* atau FP (*False Positive*) sebanyak 1 (satu) dan salah dalam mendeteksi citra dengan penyakit *others* atau FN (*False Negative*) sebanyak 3 (tiga).

Tabel 3. Nilai Accuracy, Precision, Recall, dan F1 Score

Arsitektur	Accuracy	Precision	Recall	F1 Score
tanpa SE	82.22%	95.00%	73.08%	82.61%
dengan SE	91.11%	95.00%	88.00%	90.48%

Pada Tabel 3, hasil nilai *accuracy*, *precision*, *recall* dan *f1-score* yang didapatkan dengan melakukan perhitungan berdasarkan nilai – nilai pada *confusion matrix* untuk model terbaik tanpa *SE-Net* mendapatkan *accuracy* 82.22%, *precision* 95.00%, *recall* 73.08%, dan *F1 Score* 82.61%. Sementara, untuk model terbaik dengan *SE-Net* mendapatkan

*accuracy* 91.11%, *precision* 95.00%, *recall* 88.00%, dan *F1 Score* 90.48%.

#### 4. KESIMPULAN

Penerapan arsitektur baru pada *pre-trained* model *InceptionV3* dalam mendeteksi penyakit *mpox* berhasil dilakukan terbukti dengan peningkatan akurasi dari penelitian *pre-trained* model *InceptionV3* dari 74.07% menjadi 82.22%. Namun, masih belum mampu mendapatkan akurasi yang jauh lebih baik dari *pre-trained* model *ResNet50* di angka 82.96% yang menjadi *pre-trained* model tertinggi. Namun, dengan menambahkan blok *SE-Net* terbukti mampu meningkatkan akurasi arsitektur baru pada *pre-trained* model *InceptionV3* dalam mendeteksi penyakit *mpox* terbukti dari hasil akurasi dari 82.22% menjadi 91.11% dan membuat performa model menjadi lebih baik dari *ResNet50*. Tidak hanya akurasi yang meningkat, nilai *recall*, *F1 Score* juga mengalami peningkatan dengan *recall* dari 73.08% menjadi 86.36%, dan *F1 Score* dari 82.61% menjadi 90.48%.

#### DAFTAR PUSTAKA

- ALI, S.N., AHMED, MD.T., PAUL, J., JAHAN, T., SANI, S.M.S., NOOR N. and HASAN, T., 2022. Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study. [online] Available at: <<http://arxiv.org/abs/2207.03342>>.
- BAJAJ, V. and SINHA, G.R., 2022. *Artificial Intelligence-Based Brain-Computer Interface*. Elsevier. <https://doi.org/10.1016/C2021-0-00055-9>.
- GOOGLE, 2023. *Advanced Guide to Inception v3*. [online] Available at: <<https://cloud.google.com/tpu/docs/inception-v3-advanced>> [Accessed 9 October 2023].
- HU, J., SHEN, L. and SUN, G., 2018. *Squeeze-and-Excitation Networks*. [online] Available at: <<http://image-net.org/challenges/LSVRC/2017/results>>.
- KAGGLE, 2023. *Monkeypox Skin Lesion Dataset*. [online] 2022. Available at: <<https://www.kaggle.com/datasets/nafin59/monkeypox-skin-lesion-dataset>> [Accessed 9 October 2023].
- KARHUMEN, J., RAIKO, T. and CHO, K., 2015. Unsupervised deep learning. In: *Advances in Independent Component Analysis and Learning Machines*. Elsevier. pp.125–142. <https://doi.org/10.1016/B978-0-12-802806-3.00007-5>.
- EL NAQA, I. and MURPHY, M.J., 2015. What Is Machine Learning? In: *Machine Learning in Radiation Oncology*. Cham: Springer International Publishing. pp.3–11. [https://doi.org/10.1007/978-3-319-18305-3\\_1](https://doi.org/10.1007/978-3-319-18305-3_1).
- PARKER, S. and BULLER, R.M., 2013. A review of experimental and natural infections of animals with monkeypox virus between 1958 and 2012. *Future Virology*, 8(2), pp.129–157. <https://doi.org/10.2217/fvl.12.130>.
- SARKER, I.H., 2021. Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, 2(6), p.420. <https://doi.org/10.1007/s42979-021-00815-1>.
- SZEGEDY, C., VANHOUCHE, V., IOFFE, S., SHLENS, J. and WOJNA, Z., 2016. Rethinking the Inception Architecture for Computer Vision. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. pp.2818–2826. <https://doi.org/10.1109/CVPR.2016.308>.
- WHO, 2022a. Monkeypox Fact Sheets. [online] Available at: <<https://www.who.int/news-room/fact-sheets/detail/monkeypox>> [Accessed 22 December 2023].
- WHO, 2022b. *Monkeypox Response in Europe*. [online] Available at: <<https://www.who.int/news-room/feature-stories/detail/monkeypox-response-in-europe>> [Accessed 18 December 2023].
- WHO, 2022c. *Mpox (monkeypox)*. [online] Available at: <<https://www.who.int/news-room/questions-and-answers/item/monkeypox>> [Accessed 10 December 2022].
- YE, J. and TOYAMA, N., 2021. Benchmarking Deep Learning Models for Automatic Ultrasonic Imaging Inspection. *IEEE Access*, 9, pp.36986–36994. <https://doi.org/10.1109/ACCESS.2021.3062860>.
- ZUMLA, A., VALDOLEIROS, S.R., HAIDER, N., ASOGUN, D., NTOUMI, F., PETERSEN, E. and KOCK, R., 2022. Monkeypox outbreaks outside endemic regions: scientific and social priorities. *The Lancet Infectious Diseases*, 22(7), pp.929–931. [https://doi.org/10.1016/S1473-3099\(22\)00354-1](https://doi.org/10.1016/S1473-3099(22)00354-1).

*Halaman ini sengaja dikosongkan.*