

Implementasi Algoritma CNN dalam Identifikasi Infeksi Jamur Superfisialis

Alfandi Mualo¹, Fawwaz Ikbar², Elya Juni Arta Sinaga³, Eka Yulia Putri⁴

^{1,2,3,4}Program Studi Ilmu Komputer, Universitas Negeri Medan

Jalan Willem Iskandar, Pasar V Medan Estate, (061) 6613365

Email: alfandif123@gmail.com¹, fawwazcanaiago@gmail.com², elyasinaga15@gmail.com³, ekayuliaputri33@gmail.com⁴

Abstract. Mushrooms, as eukaryotic organisms that dominate the kingdom Fungi, play a crucial role as decomposers of organic matter in ecosystems. The diversity of mushrooms encompasses a variety of species, ranging from microscopic to macroscopic, widely distributed in various environments. Superficial fungal infections, or superficial mycoses, focus on fungal infections limited to the surface of the skin, nails, or hair. Such infections are typically localized, not penetrating deep into tissues and remain primarily a local condition. In the context of this study, the optimal model developed through training successfully achieved a validation accuracy of 92.590% and a training accuracy of 88.933%. Evaluation results indicate a precision value of 94%, a recall value of 93%, and an F1-score value of 92%. These findings highlight the success of the model in classifying and evaluating superficial fungal infections with high precision.

Keywords: Fungal Infections, Convolutional Neural Network, MobileNetV3.

Abstrak. Jamur, sebagai organisme eukariotik yang mendominasi kerajaan fungi, memegang peran krusial sebagai pengurai materi organik dalam ekosistem. Keanekaragaman jamur mencakup spesies-spesies yang bervariasi, mulai dari yang mikroskopis hingga makroskopis, tersebar luas di berbagai lingkungan. Infeksi jamur superfisial, atau mikoza superfisial, terfokus pada infeksi jamur yang terbatas pada permukaan kulit, kuku, atau rambut. Infeksi semacam ini biasanya bersifat terlokalisir, tidak menembus jauh ke dalam jaringan dan bersifat kondisional secara lokal. Dalam konteks penelitian ini, model optimal yang diperoleh melalui pelatihan berhasil mencapai tingkat akurasi validasi sebesar 92.590% dan akurasi pelatihan sebesar 88.933%. Hasil evaluasi menunjukkan nilai presisi sebesar 94%, nilai recall sebesar 93%, dan nilai F1-score sebesar 92%.

Kata kunci: Infeksi Jamur, Convolutional Neural Network, MobileNetV3.

LATAR BELAKANG

Fungi atau lebih dikenal dengan istilah jamur merupakan kingdom dari organisme eukariotik bersifat heterotrof yang mendapat nutrisinya dari bahan organik (Whittaker, n.d.). Sebagai organisme yang paling banyak tersebar di bumi, jamur sangat berperan penting sebagai agen pengendali biologis karena berkontribusi terhadap keseimbangan ekosistem bumi sebagai dekomposer yang baik (Naranjo-Ortiz & Gabaldón, 2019).

Namun demikian, tidak sedikit pula jamur yang menyebabkan penyakit karena bersifat parasit pada tanaman budidaya, hewan ternak, bahkan pada manusia. Penyakit yang disebabkan oleh jamur disebut infeksi jamur atau mikosis. Biasanya infeksi jamur sering terjadi pada kulit dan kuku, namun infeksi jamur juga dapat menyerang mulut, tenggorokan, saluran kemih, paru-paru dan anggota tubuh lainnya (Ameen, 2010).

Prevalensi akibat infeksi jamur jauh lebih besar dari perkiraan. Infeksi jamur superfisial atau infeksi jamur yang menyerang kulit, rambut dan kuku dilaporkan menyerang 20% - 25% populasi dunia dengan dominasi infeksi dermatofita (Howell, 2023). Diagnosis infeksi jamur superfisial memerlukan pemeriksaan laboratorium dengan pemeriksaan mikroskopis jaringan untuk mendeteksi keberadaan jamur, dan kultur untuk mengidentifikasi patogen (Rosida & Ervianti, n.d.).

Seiring dengan kemajuan teknologi hampir semua sektor baik medis atau lainnya mengandalkan sistem komputerisasi untuk menggantikan teknologi konvensional sehingga dapat memudahkan tenaga medis dalam melakukan diagnosis (Wulan Dari & Triloka, n.d.). Salah satu teknik yang dapat diterapkan dalam sistem ini adalah menggunakan algoritma CNN (Convolutional Neural Network). CNN merupakan evolusi dari Multilayer Perceptron (MLP) yang dirancang khusus untuk memproses data 2D. Klasifikasi CNN termasuk dalam kategori Deep Neural Network karena memiliki struktur jaringan yang kompleks dan telah sukses diimplementasikan dalam pemrosesan data citra (Yohannes & Al Rivan, 2022).

Penelitian lain mengenai infeksi jamur yaitu pendeteksian penyakit kulit pada kucing dengan menggunakan algoritma CNN berbasis android, dimana kucing sangat rawan terinfeksi jamur yang juga dapat menularkannya ke manusia. Dengan hasil akurasi yang didapatkan sebesar 78,33% (Sistem et al., 2023). Penelitian lainnya yaitu proses pendeteksian penyakit kulit pada wajah dimana salah satu disebabkan oleh infeksi jamur menggunakan metode CNN dengan arsitektur LeNet-5 yang menghasilkan akurasi sebesar 81% (Ath-thariq et al., 2023).

Berdasarkan uraian di atas, penelitian ini bertujuan membangun model menggunakan yang dapat membantu dalam pengenalan dan diagnosis jenis infeksi jamur menggunakan metode CNN diharapkan bahwa penelitian ini dapat memberikan kontribusi dalam upaya pencegahan, pengenalan dini, dan pengobatan dari infeksi jamur.

KAJIAN TEORITIS

Deep Learning

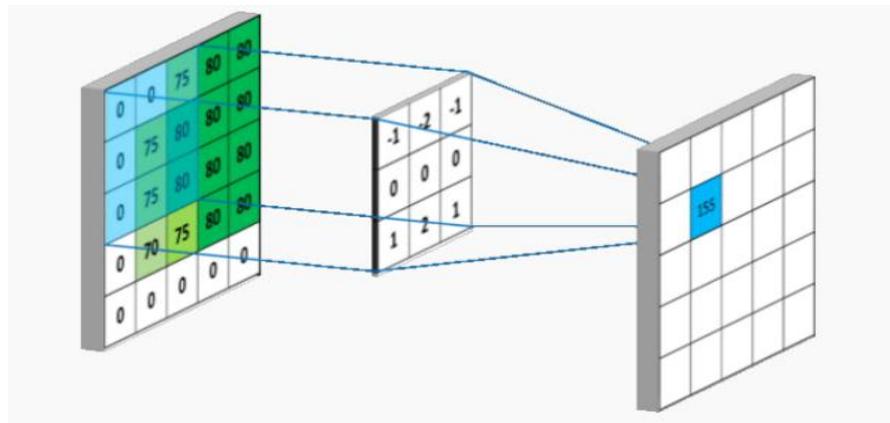
Deep Learning atau yang juga dikenal sebagai deep structured learning, hierarchical learning, atau deep neural learning merupakan bagian dari Machine Learning yang memanfaatkan Jaringan Syaraf Tiruan untuk membimbing komputer dalam menjalankan tugas-tugas mirip manusia. Komputer diarahkan untuk mengklasifikasikan dan mengenali data yang berasal dari berbagai sumber seperti gambar, suara, teks, atau video. Teknik ini mencerminkan pola berpikir manusia dan menggunakan metode Artificial Neural Networks dengan struktur yang bersifat multilayer (Suartika E. P, 2016).

Convolutional Neural Network

Convolutional Neural Network (CNN) adalah kategori jaringan saraf yang dirancang khusus untuk memecahkan masalah pemrosesan gambar. Algoritma CNN telah terbukti menjadi metode yang efektif untuk mengklasifikasikan, mengidentifikasi, dan mengenali pola dalam gambar. Keunggulan algoritma ini adalah kemampuannya dalam memahami detail gambar berdasarkan arsitektur yang sesuai dengan cara otak manusia memproses informasi visual. CNN mengambil data dua dimensi, seperti gambar atau suara, dan menerapkan operasi konvolusi ke matriks berbobot empat dimensi yang terdiri dari sekumpulan kernel konvolusi (ANHAR & PUTRA, 2023).

Convolutional Layer

Layer Konvolusi melakukan operasi Convolution pada output dari layer sebelumnya, dan merupakan elemen kunci dalam struktur Convolutional Neural Network (CNN). Dalam konteks ini, konvolusi mengacu pada penerapan fungsi pada hasil keluaran fungsi lain secara berulang. Saat diterapkan pada data citra, tujuan konvolusi adalah mengekstraksi fitur signifikan dari citra input. Proses konvolusi menghasilkan transformasi linear dari data input, mencerminkan informasi spasial dalam data tersebut. Bobot di layer konvolusi menentukan kernel konvolusi yang digunakan, dan melalui proses pelatihan pada CNN, kernel konvolusi dapat disesuaikan berdasarkan input yang diterima (Suartika E. P, 2016).

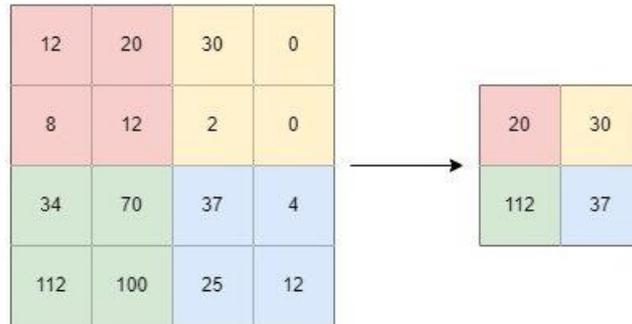


Gambar 1. Convolutional Layer

Pooling Layer

Layer Penggabungan (Pooling Layer) adalah elemen esensial dalam struktur Convolutional Neural Network (CNN) yang memanfaatkan fungsi dengan Feature Map sebagai masukan dan melaksanakan operasi statistik berdasarkan nilai piksel terdekat. Dalam konfigurasi CNN, umumnya, lapisan Pooling ditempatkan secara teratur setelah beberapa lapisan konvolusi. Pemasangan berturut-turut lapisan Pooling di antara lapisan Konvolusi

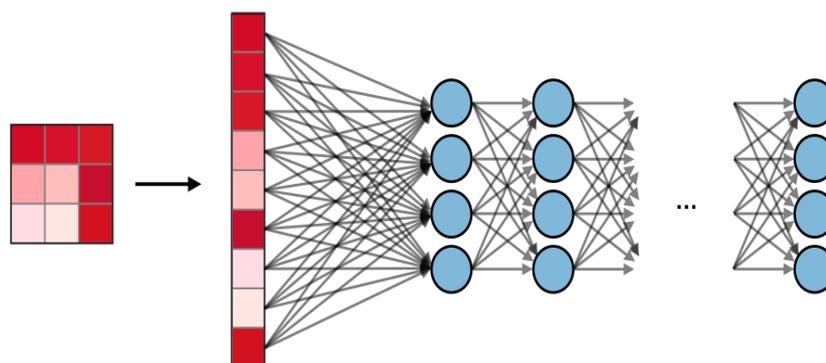
dalam struktur model CNN secara progresif mengurangi dimensi volume keluaran pada Feature Map. Tindakan ini tidak hanya mengurangi jumlah parameter dan perhitungan di dalam jaringan, melainkan juga berkontribusi dalam mengontrol Overfitting (Ilahiyah & Nilogiri, 2018).



Gambar 2. Pooling Layer

Fully Connected Layer

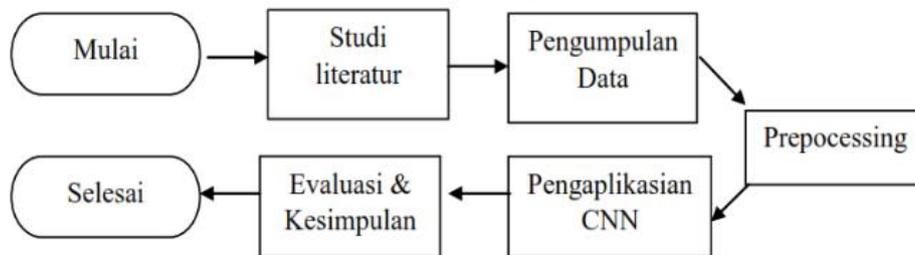
Fully Connected Layer umum digunakan pada implementasi Multi-Layer Perceptron (MLP) dan bertujuan untuk mengubah dimensi data agar dapat diklasifikasikan secara linear. Sebelum dapat dimasukkan ke dalam layer sepenuhnya terhubung, setiap neuron di lapisan konvolusi perlu mengalami transformasi menjadi data satu dimensi terlebih dahulu. Meskipun proses ini menyebabkan kehilangan informasi spasial secara tidak dapat dikembalikan, fully connected layer hanya dapat diimplementasikan di bagian akhir jaringan (Ilahiyah & Nilogiri, 2018).



Gambar 3. Fully Connected Layer

METODE PENELITIAN

Pada proses penelitian diperlukan penjabaran langkah langkah apa saja yang akan dilakukan dalam penelitian. Berikut ini adalah alur penelitian yang di representasikan pada gambar 4.



Gambar 4. Alur Penelitian

Studi Literatur

Dalam melakukan studi literatur, peneliti terlibat dalam serangkaian kegiatan seperti analisis, evaluasi, dan sintesis literatur. Sumber-sumber yang digunakan melibatkan referensi dari berbagai jenis, termasuk jurnal ilmiah, buku, situs web, dan sumber terpercaya lainnya. Tujuan utama dari studi literatur adalah untuk mendapatkan wawasan yang komprehensif tentang kerangka kerja penelitian yang telah ada sebelumnya.

Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan dengan mencari data secara online dimana peneliti mendapat data dari UCI Machine Learning <https://archive.ics.uci.edu/dataset/773/defungi>. Dataset yang digunakan yaitu gambar dengan format jpg yang berjumlah 9114 gambar.

Preprocessing Data

Tujuan dari proses preprocessing atau pengolahan data adalah untuk mempersiapkan data mentah agar dapat dimanfaatkan secara efisien dalam penelitian. Pada tahap preprocessing data, dataset dipartisi menjadi dua bagian, yakni data pelatihan (training) dan data pengujian (testing). Pembagian ini dilakukan dengan proporsi 80% untuk data pelatihan dan 20% untuk data pengujian. Ukuran gambar pada data pelatihan dan data validasi diubah menjadi 244 x 244 piksel. Selama pelatihan, batch size sebesar 32 digunakan, sehingga setiap iterasi melibatkan pemrosesan sebanyak 32 sampel data gambar. Langkah ini bertujuan untuk memastikan bahwa data yang akan digunakan dalam penelitian telah disiapkan dengan baik dan siap untuk digunakan.

Pengaplikasian CNN

Dalam fase ini, dilakukan perancangan struktur Convolutional Neural Network (CNN) yang akan diterapkan dalam penelitian dengan mengonfigurasi parameter-parameter yang akan digunakan. Pada pembentukan model dilakukan pendekatan transfer learning di mana pengetahuan yang telah diperoleh oleh model dari dataset ImageNet dimanfaatkan tanpa perubahan pada bobotnya. Penggunaan model Keras berjenis Sequential dipilih untuk berfungsi sebagai wadah bagi setiap lapisan yang akan ditambahkan. Model dasar yang digunakan dalam dataset defungi adalah MobileNetV3Small, yang diintegrasikan sebagai lapisan pertama dalam model Keras yang telah dibentuk. Kemudian pada pelatihan model, digunakan optimasi Adam untuk mengoptimalkan bobot model sepanjang proses pelatihan. Fungsi cross-entropy dipilih untuk menangani tugas klasifikasi dengan beberapa kelas, di mana one-hot encoding pada label tidak diperlukan. Model dilatih menggunakan data dari dataset pelatihan, dan evaluasi model dilakukan dengan memanfaatkan data dari dataset validasi. Proses pelatihan dilakukan selama 15 epoch untuk mencapai pembelajaran yang optimal

Evaluasi dan Kesimpulan

Dalam fase evaluasi, penjelasan diberikan mengenai bagaimana model Convolutional Neural Network (CNN) yang telah dibangun akan mengevaluasi kinerjanya. Proses evaluasi ini melibatkan analisis pengukuran kinerja model menggunakan confusion matrix, di mana hasil prediksi model dibandingkan dengan label yang sebenarnya. Dari perbandingan ini, kesimpulan akan ditarik berdasarkan hasil evaluasi untuk menilai sejauh mana model dapat memberikan prediksi yang akurat.

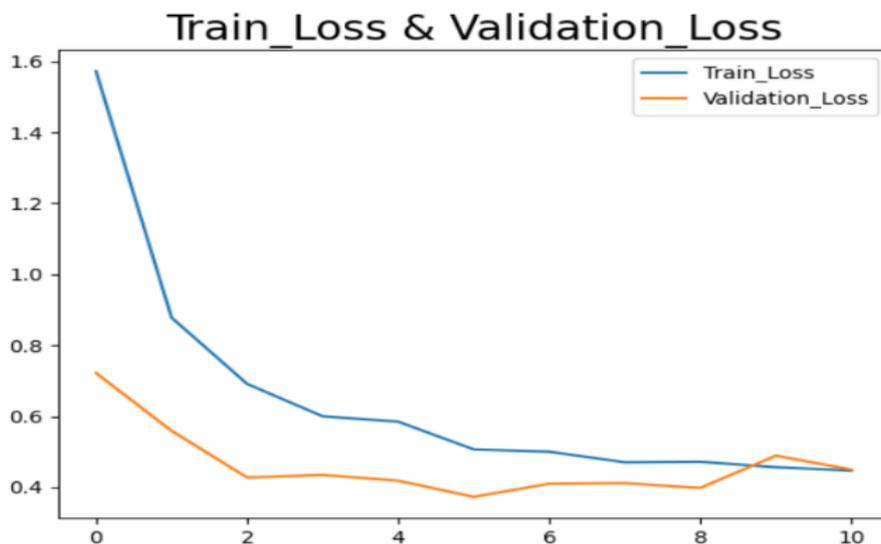
HASIL DAN PEMBAHASAN

Penelitian ini menerapkan Algoritma Convolutional Neural Network (CNN) dalam proses pengenalan dataset defungi menggunakan Jupyter Notebook. Dataset yang digunakan diperoleh secara daring dari UCI Machine Learning. Dataset ini terdiri dari gambar dalam format jpg, total sebanyak 9114 gambar, di mana 80% digunakan sebagai data pelatihan dan 20% sebagai data pengujian.

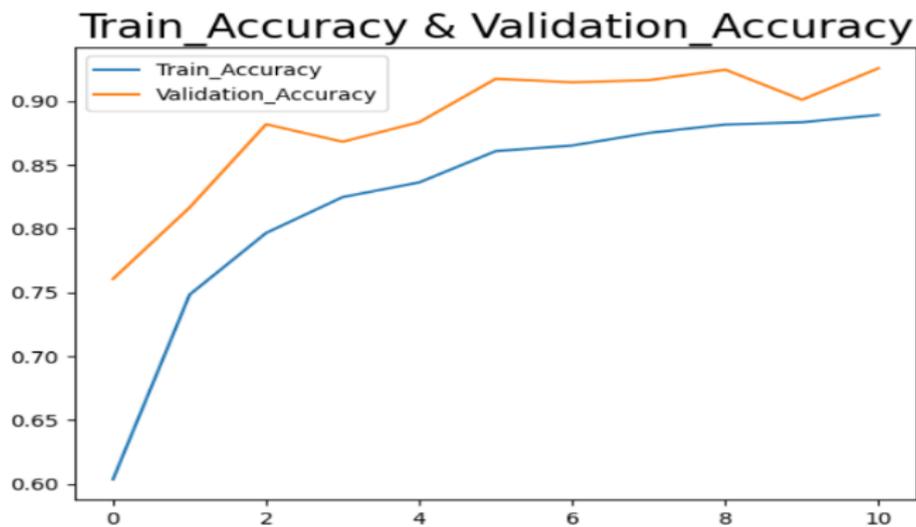
Tabel 1. Akurasi Model

No.	Loss	Accuracy	Validation Loss	Validation Accuracy
1	1.5718	0.6035	0.7218	0.7607
2	0.8779	0.7483	0.5590	0.8166
3	0.6912	0.7967	0.4274	0.8819
4	0.5998	0.8248	0.4345	0.8682
5	0.5847	0.8363	0.4185	0.8836
6	0.5066	0.5066	0.3730	0.9176
7	0.5001	0.8653	0.4099	0.9149
8	0.4703	0.8752	0.4116	0.9165
9	0.4717	0.8817	0.3980	0.9248
10	0.4564	0.8835	0.4890	0.9012
11	0.4470	0.8893	0.4496	0.9259

Tabel di atas memberikan gambaran mengenai iterasi epoch dari epoch 1 hingga epoch 11. Dapat diamati bahwa seiring meningkatnya jumlah epoch, terjadi penurunan pada nilai loss dan peningkatan pada akurasi pada model pelatihan. Pada epoch terakhir, diperoleh nilai pelatihan loss sebesar 0.4470 dan akurasi pelatihan sebesar 0.8893 untuk pelatihan, sementara untuk validasi diperoleh nilai loss 0.4496 dan akurasi evaluasi sebesar 0.9252.

**Gambar 5. Grafik training loss dan validation loss**

Pada grafik training loss dan validation loss di atas dapat terlihat menurun dengan stabil seiring dengan bertambahnya epoch.



Gambar 6. Grafik training accuracy dan validation accuracy

Pada grafik training accuracy dan validation accuracy diatas dapat terlihat meningkat dengan stabil seiring dengan bertambahnya epoch.

Tabel 2. Matriks Evaluasi Klasifikasi

No.	Precision	Recall	F1-score
1	0.93	0.92	0.93
2	0.84	0.88	0.86
3	0.94	0.87	0.91
4	0.98	0.99	0.98
5	0.97	0.99	0.98
Micro	0.94	0.93	0.92
Macro	0.94	0.93	0.93
Weighted	0.92	0.92	0.92

Berdasarkan Tabel di atas menampilkan hasil metrik evaluasi, termasuk precision, recall, dan F1-score, untuk model yang dievaluasi. Pendekatan Micro average memberikan penekanan yang lebih besar pada kelas-kelas yang memiliki frekuensi lebih tinggi, sementara pendekatan Macro average memberikan perhatian setara pada setiap kelas tanpa mempertimbangkan ukuran kelas. Di sisi lain, pendekatan Weighted average memberikan perhatian sesuai dengan ukuran kelas, sehingga memberikan nilai lebih tinggi pada kelas dengan frekuensi yang lebih besar.

Dalam konteks dataset defungi, hasil evaluasi menunjukkan nilai precision sebesar 0.94, nilai recall sebesar 0.93, dan nilai F1-score sebesar 0.92. Hasil ini memberikan gambaran komprehensif tentang performa model dalam mengklasifikasikan kelas-kelas pada dataset tersebut.

KESIMPULAN DAN SARAN

Dari hasil pengujian yang diperoleh dalam penelitian ini, dapat ditarik beberapa simpulan sebagai berikut:

1. Dari hasil evaluasi yang diperoleh menunjukkan nilai precision sebesar 0.94, nilai recall sebesar 0.93, dan nilai F1-score sebesar 0.92.
2. Hasil loss pelatihan sebesar 0.4470 dan tingkat akurasi pelatihan sebesar 0.8893, sedangkan untuk validasi terdapat hasil loss sebesar 0.4496 dan akurasi evaluasi sebesar 0.9252.

DAFTAR REFERENSI

- Ameen, M. (2010). Epidemiology of superficial fungal infections. *Clinics in Dermatology*, 28(2), 197–201. <https://doi.org/10.1016/J.CLINDERMATOL.2009.12.005>
- ANHAR, A., & PUTRA, R. A. (2023). Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN). *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(2), 466. <https://doi.org/10.26760/elkomika.v11i2.466>
- Ath-thariq, M., Suharsono, T. N., Studi, P., Informatika, T., & Buana, U. S. (2023). *Deteksi Penyakit Kulit Serupa Pada Wajah Berbasis Mobile dengan Metode Convolutional Neural Network*. 3, 876–887.
- Howell, S. A. (2023). Dermatopathology and the Diagnosis of Fungal Infections. In *British Journal of Biomedical Science* (Vol. 80). Institute of Biomedical Science (IBMS). <https://doi.org/10.3389/bjbs.2023.11314>
- Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 3(2), 49–56.
- Naranjo-Ortiz, M. A., & Gabaldón, T. (2019). Fungal evolution: major ecological adaptations and evolutionary transitions. *Biological Reviews*, 94(4), 1443–1476. <https://doi.org/10.1111/brv.12510>
- Rosida, F., & Ervianti, E. (n.d.). *Penelitian Retrospektif: Mikosis Superfisialis (Retrospective Study: Superficial Mycoses)*.
- Sistem, P., Penyakit, D., Pada, K., Menggunakan, K., Pangestu, I. Y., & Ramadhani, S. R. (2023). *Perancangan Sistem Deteksi Penyakit Kulit Pada Kucing Menggunakan Deep Learning Berbasis Android Design of Skin Disease Detection System in Cats Using Android-Based Deep Learning*. 12(November), 173–182. <https://doi.org/10.34148/teknika.v12i3.673>

- Suartika E. P, I. W. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101. *Jurnal Teknik ITS*, 5(1), 76. <http://repository.its.ac.id/48842/>
- Whittaker, R. H. (n.d.). (*New Concepts of Kingdoms of Organisms*).
- Wulan Dari, S., & Triloka, J. (n.d.). *Kajian Algoritme Mask Region-Based Convolutional Neural Network (Mask R-CNN) dan You Look Only Once (YOLO) Untuk Deteksi Penyakit Kulit Akibat Infeksi Jamur*.
- Yohannes, R., & Al Rivan, M. E. (2022). Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM. *Jurnal Algoritme*, 2(2), 133–144. <https://doi.org/10.35957/algoritme.v2i2.2363>