

Klasifikasi Penyakit Daun Jagung Menggunakan Lightweight Convolutional Neural Network

Andri Lesmana Hermawan^a

^aTeknik Informatika, Universitas Darussalam Gontor

aandrilesmanahermawan@mhs.unida.gontor.ac.id

Intisari

Tentang naskah:

-diterima, 1 Jul. 2023
-direview, 17 Jul. 2023
-diterbitkan, 31
Jul.2023

Kata kunci:

*Deep Learning, Jaringan
Saraf Konvolusi Ringan,
Penyakit Daun Jagung,
Oversampling, Pre-
Trainde Model*

Deep Neural Network telah mencapai kesuksesan luar biasa dalam banyak tugas dan penelitian terutama dalam pengenalan pola. Namun, komputasi yang tinggi dan kebutuhan memori yang besar menghalangi mereka dalam mengaplikasikan pada perangkat yang terbatas dan perlunya biaya yang besar. Dan Ketidakseimbangan data dalam Pembelajaran Mesin mengacu pada distribusi kelas yang tidak merata dalam kumpulan data. Masalah ini sering ditemui dalam tugas klasifikasi di mana distribusi kelas dalam kumpulan data tertentu tidak seragam. Dengan adanya masalah-masalah tersebut maka peneliti mengusulkan metode Jaringan Saraf Ringan serta menambahkan metode Resampling pada data Penyakit Daun Jagung, untuk meringankan proses komputasi dan menyeimbangkan data. Peneliti menggunakan beberapa metode dalam pembelajaran mesin yang melibatkan penggunaan pengetahuan yang telah dipelajari oleh model yang sudah ada (Transfer Learning) antara lain : MobileNet, EfficientNetB1 dan Exception, serta melakukan perbandingan antar model. Model-model tersebut menggunakan teknik Depthwise Separable Convolution untuk mengurangi jumlah parameter dan operasi konvolusi yang perlu dilakukan, sehingga mengurangi kebutuhan komputasi dan kompleksitas model. Hasil dari penelitian jaringan saraf ringan serta kombinasi Resampling, model Transfer Learning yang paling tinggi sebesar 95% yang di peroleh dari model EfficientNetB1 daripada model Transfer learning lainnya.

Abstract

Keyword:

*Deep Learning
Lightweight
Convolutional Neural
Network, Corn Leaf
Desease, Oversampling,
Pre-Trainde Mpdel*

Deep Neural Networks have achieved great success in many tasks and research especially in pattern recognition. However, high computing and large memory requirements prevent them from being applied to limited devices and require large costs. And Imbalance of data in Machine Learning refers to the unequal distribution of classes in a data set. This problem is often encountered in classification tasks where the distribution of classes within a given data set is not uniform. Given these problems, the researchers proposed the Light Neural Network method and added the Resampling method to Corn Leaf Disease data, to ease the computational process and balance the data. Researchers use several methods in machine learning which involve the use of knowledge that has been learned by existing models (Transfer Learning), including: MobileNet, EfficientNetB1 and Exception, as well as conducting comparisons between models. These models use the Depthwise Separable Convolution technique to reduce the number of parameters and convolution operations that need to be performed, thereby reducing the computational requirements and model complexity. The results of light neural network research and the combination of Resampling, the highest Transfer Learning model of 95% obtained from the EfficientNetB1 model than other Transfer learning models.

1. Pendahuluan

Jagung merupakan tumbuhan yang termasuk kebutuhan primer urutan ketiga sesudah padi dan gandum didunia, jika di Indonesia berada pada urutan kedua. Tumbuhan jagung dapat bertumbuh dengan baik bahkan pada cuaca panas dan dingin dengan didukung irigasi yang baik. Semasa siklus hidup jagung dari benih ke benih, setiap bagian

pada tumbuhan jagung memiliki kepekaan terhadap sejumlah penyakit terutama pada area daun, yang menyebabkan jagung mengalami penurunan kuantitas dan kualitas hasil(Azizah 2023). Penyakit tanaman adalah salah satu elemen paling kritis yang berdampak pada produksi pangan. Mereka (penyakit daun) penyebab atas penurunan yang signifikan dalam produktivitas ekonomi tanaman, serta

menjadi penghalang aktivitas ini dalam beberapa kasus. Menurut, manajemen penyakit dan prosedur pengendalian harus dilakukan secara efektif untuk mengurangi kerugian keluaran dan memastikan keberlanjutan pertanian, menggarisbawahi pentingnya pemantauan tanaman berkelanjutan yang dipasangkan dengan deteksi penyakit yang cepat dan akurat (Tugrul, Elfatimi, and Eryigit 2022).

Pembelajaran mendalam memiliki potensi besar untuk prediksi penyakit yang akurat dengan data neuroimaging, tetapi kinerja prediksi seringkali dibatasi oleh ukuran set data pelatihan dan persyaratan memori komputasi (Peng et al. 2021). Data pada penelitian ini terbilang tidak seimbang antara kelas, Masalah ketidakseimbangan kelas dan ketidaklengkapan data terjadi secara bersamaan di banyak kumpulan data klasifikasi, yang secara negatif bisa memengaruhi kinerja pada proses pelatihan pengklasifikasi (Shin, Han, and Kang 2021). Oleh karena itu peneliti menambahkan metode Random Oversampling pada penelitian ini.

Dengan adanya masalah yang telah dipaparkan peneliti. Harapan peneliti untuk bisa memecahkan masalah ini, peneliti berfokus pada bagaimana sumber daya yang rendah dalam komputasi dan ketidakseimbangan pada data.

2. Kerangka Teori

2.1. Jagung dan Jenis Penyakit Daun Jagung


Jagung salah satu kebutuhan pangan utama setelah padi dan terigu di dunia dan termasuk kebutuhan yang penting di Indonesia setelah padi. Berdasarkan organisasi pertanian dunia (FAO) Indonesia merupakan negara penghasil jagung terbesar dunia di akhir tahun 2017. Namun, faktor penyakit pada jagung mengakibatkan rendahnya produksi jagung. Pada daun jagung ada 4 jenis penyakit utama yaitu penyakit karat daun, penyakit bercak daun, penyakit hawar daun, dan bulai daun (Rosadi, Lutfi, and Artikel n.d.). adanya sistem berbasis Digital Image Processing untuk menentukan tingkat penyakit daun, maka peneliti mencoba mengimplementasikan sistem tersebut. Sistem dibangun dengan terdiri dari beberapa sub proses. Pertama, proses segmentasi, sistem akan melakukan pencarian piksel-piksel perkiraan penyakit daun jagung, dengan

memanfaatkan fitur komponen warna r, g, b, dari setiap penyakit daun kemudian menghitung besar ketidaksamaan (jarak Euclidean) terhadap nilai fitur data (Rianto P and Harjoko A 2017)

2.2. Deep Learning

Konsep terpenting dalam bidang pembelajaran yang mendalam. Ini terinspirasi oleh sistem biologis manusia yang cenderung berfokus pada bagian-bagian khusus saat memproses informasi dalam jumlah besar (Niu, Zhong, and Yu 2021).

Pembelajaran mendalam cabang pembelajaran mesin adalah untuk kecerdasan buatan, yang bertujuan untuk lebih dekat dengan tujuan utamanya yaitu kecerdasan buatan. Penelitian ini terutama mengadopsi ringkasan dan metode induksi pembelajaran mendalam untuk memproses pola citra pada penyakit daun jagung (Dong, Wang, and Abbas 2021). Simulasi dari proses Deep Learning kurang lebih seperti yang ditampilkan pada Gambar 1.



Gambar 1. Simulasi Deep Learning

2.3. Jaringan Saraf Ringan

Model klasifikasi yang ringan dan akurat secara kompetitif berdasarkan jaringan saraf konvolusional klasik dalam jaringan saraf yang dalam dan teknik akselerasi perangkat keras untuk mengatasi kekurangan perangkat. (Gu et al. 2023)

jaringan saraf convolutional ringan, untuk segmentasi yang akurat secara real-time. jaringan saraf convolutional ringan berupaya merancang arsitektur jaringan yang lebih dalam, sembari mempertahankan kecepatan inferensi yang lebih cepat dan akurasi segmentasi yang lebih tinggi. Jaringan penelitian ini menggunakan depth-wise separable convolution yang terfaktorisasi untuk mempelajari representasi fitur dari berbagai bidang reseptif skala dengan

parameter model yang lebih sedikit(Liu et al. 2020).

Depth-wise sendiri Teknik yang terdapat pada MobileNet dan Xception, berbeda dengan EfficientNetB1 yang menggunakan komponen Penskalaan. Proses penskalaan basis jaringan konvolusional untuk memberinya kompleksitas komputasi yang lebih besar dan kekuatan representasional atau objek yang bisa dikenali(Dollár, Singh, and Girshick 2021)

2.4. Oversampling

Ketidakeimbangan kelas adalah suatu kondisi ketika satu kelas memiliki persentase yang lebih tinggi dari yang lain sehingga menyebabkan mempengaruhi akurasi.(Ustyannie and Suprpto 2020) Penelitian ini dilakukan penanganan ketidakseimbangan kelas terhadap kelas minoritas (data terkecil) menggunakan teknik oversampling.(Sulistiyono et al. 2021) Metode Resampling alat yang sangat diperlukan dalam statistik modern. Mereka (Resampling) melibatkan berulang kali mengambil sampel dari set pelatihan dan memasang kembali model yang menarik pada setiap sampel untuk mendapatkan informasi tambahan tentang model yang dipasang.(James et al. 2013) Oleh karena itu, penting untuk menangani masalah kemiringan data ini saat melatih algoritme pembelajaran mesin.(Khushi et al. 2021)

2.5. Transfer Learning Pre-Trained Model

Penggunaan metode deep learning untuk deteksi telah menunjukkan hasil yang cukup baik. Namun, deep learning membutuhkan waktu komputasi pelatihan yang lama dengan epoch pelatihan yang besar untuk mendapatkan akurasi yang tinggi. Penelitian ini memanfaatkan Transfer Learning untuk mengurangi waktu pelatihan(Spectrogram and Learning 2022). Transfer Learning salah satu solusi yang bisa dimanfaatkan pada saat dataset yang ada tidak cukup ideal untuk melakukan proses training dari awal. Tujuan dari penelitian ini adalah memanfaatkan arsitektur model yang sudah dilatihkan sebelumnya (pretrained model), transfer learning mampu meningkatkan akurasi model dengan melatih ulang model menggunakan dataset yang tidak terlalu banyak(Rochman Fadlur 2020).

Transfer learning adalah metode penggunaan kembali model atau pengetahuan untuk tugas terkait lainnya.

Transfer learning juga dianggap sebagai perpanjangan dari algoritma Machine Learning(Sarkar, Bali, and Ghosh 2018).

Pembelajaran Transfer Learning terutama berfokus pada pengoptimalan bobot model pra-pelatihan, yang mengabaikan ketidaksesuaian struktur antara model dan tugas target(Liu et al. 2021).


3. Metodologi

3.1. Pengumpulan Dataset

Dilakukan pengumpulan dataset Corn or Maize Leaf Disease Dataset berasal dari Kaggle yang telah tervalidasi oleh para peneliti(Singh D, Jain N, Jain P, Kayal P, Kumawat S 2021). Jumlah dataset yang digunakan dapat dilihat pada Tabel 1 dan contoh jenis-jenis penyakit daun jagung dapat dilihat pada gambar 2.

Table 1
Dataset gambar yang digunakan

Kelas	Total Gambar
Blight	1146
Common_Rust	1306
Gray_Leaf_Spot	574
Healthy	1162
Total Dataset	4188



Gambar 2. Jenis-jenis penyakit daun jagung

3.2. Analisis Data

Tahap selanjutnya Teknik analisis data yang digunakan peneliti adalah Oversampling, Oversampling dilakukan guna meningkatkan jumlah data gambar dalam kelas minoritas sehingga seimbang


dengan jumlah sampel dalam kelas mayoritas. Berikut hasil hasil Teknik oversampling. Hasil dapat dilihat pada Table 2.

Tabel 2.

Dataset gambar setelah proses Oversampling

Kelas	Total Gambar
Blight	1146
Common_Rust	1306
Gray_Leaf_Spot	1148
Healthy	1162
Total Dataset	4188

Setelah dilakukannya oversampling pada kelas Gray_Leaf_Spot yang pada data awal 574 menjadikan 1148 data gambar. Gambar sebelum dan sesudah proses Oversampling dapat dilihat pada Gambar 3.



Gambar 3. Hasil Oversampling pada kelas Gray Leaf Spot

3.3. Perancangan

Tahap ini dilakukan perancangan mengenai penelitian dan sistem yang dilakukan selama proses penelitian klasifikasi penyakit daun jagung. Tahapan yang dilakukan adalah preprocessing yaitu resize ukuran citra menjadi 224 x 224 guna Menyesuaikan bentuk gambar dan mencoba mempertahankan konten penting(Danon et al. 2021). kemudian melakukan pembagian dataset dengan rasio 70:30, melakukan ekstraksi fitur kemudian dilakukan klasifikasi menggunakan Lightweight Convolutional Neural Network dengan arsitektur MobileNet, EfficientNetB1 dan Xception.

3.4. Analisis Hasil Pengujian

Tahap terakhir melakukan Analisis hasil pengujian Pada tahap ini dilakukan pencatatan terhadap hasil uji coba yang telah dilakukan untuk melihat hasil dan menjawab tujuan dari penelitian ini. Hasil uji coba tersebut dihitung untuk mendapatkan tingkat keberhasilan dari metode-metode yang digunakan untuk tingkat keberhasilan dari metode yang digunakan dengan Confusion Matrix Sebuah pendekatan untuk mengevaluasi prediksi dan matriks kebingungan untuk

menentukan peringkat(Hasnain et al. 2020). serta menghitung nilai Accuracy, Precision dan Recall.

4. Hasil dan Pembahasan

Pada hasil dan pembahasan, penulis melakukan penambahan data pada kelas yang tidak seimbang yaitu pada data kelas Gray_Leaf_Spot kemudian melakukan preprocessing yaitu dilakukan resize ukuran citra menjadi 224x224. Kemudian dilakukan pembagian dataset menjadi data training dan data testing dengan rasio pembagian 70:30. Setelah pembagian dataset dilakukan pelatihan data menggunakan 3 Pre-trained model dan di compile menggunakan Estimasi Momen Adaptif (Adam)(Bock and Weis 2019) batch size 10. Dengan jumlah epoch 10 untuk model MobileNet dan EfficientNetB1 serta 30 epoch untuk model Xception.

Arsitektur Model, model yang dibuat menggunakan bobot imagenet dan tidak memasukan lapisan akhir pada arsitektur yang digunakan. Peneliti menambahkan Global average pooling2D yaitu Untuk menghasilkan satu peta fitur untuk masing-masing yang sesuai kategori tugas klasifikasi di lapisan terakhir. Mengambil rata-rata dari setiap peta fitur, dan vektor yang dihasilkan diumpankan langsung ke lapisan softmax(Lin, Chen, and Yan 2014), kemudian menambahkan Dropout Ditutup dengan Dense layer dengan keluaran 4 kelas dengan activation 'softmax'.


Dari rangkaian diatas di compile menggunakan optimasi adam, dan loss categorical crossentropy yaitu Cross Entropy digunakan sebagai tujuan pelatihan, untuk meminimalkan kesalahan probabilitas rata-rata antara target dan label yang diprediksi untuk setiap piksel(Dr.A 2020). Arsitektur dapat dilihat pada Tabel 3.

Table 3
Arsitektur dari model yang dipakai

Input Layer	Output Shape	Param
MobileNet	7, 7, 1024	32228864
Global Average Pooling	1024	0
Dropout	1024	0
Dense	128	1331200
Dense_1	4	516
EfficientNetB1	7, 7, 1280	6575239
Global Average Pooling	1280	0
Dropout	1280	0

Dense	128	163968
Dense_1	4	516
Xception	7, 7, 2048	20861480
Global	2048	0
Average		
Pooling		
Dropout	2048	0
Dense	128	262272
Dense_1	4	516

MobileNet Hasil dari model yang menggunakan arsitektur MobileNet menunjukkan hasil accuracy training sebesar 0,92 dan validation accuracy sebesar 0,90. Selain itu model mendapatkan loss training sebesar 0,19 dan validation loss sebanyak 0,22. Hasil dari training menunjukkan pada epoch pertama didapatkan tingkat akurasi sebesar 80,1%, seterusnya tingkat akurasi mengalami peningkatan hingga epoch 10 sebesar 92,7%. Dapat dilihat pada gambar 4. Dan hasil confusion matrix yang ditampilkan pada Gambar 5.




Gambar 4. Hasil Training MobileNet

Confusion Matrix					
True Labels	Blight	264	8	63	3
	Common_Rust	5	352	8	2
	Gray_Leaf_Spot	25	6	330	3
	Healthy	6	1	1	352
		Blight	Common_Rust	Gray_Leaf_Spot	Healthy
Predicted Labels					

Gambar 5. Confusion Matrix MobileNet

Hasil dari model yang menggunakan arsitektur EfficientNetB1 menunjukkan hasil accuracy training sebesar 0,92 dan validation accuracy sebesar 0,90. Selain itu model mendapatkan loss training sebesar 0,19 dan validation loss sebanyak 0,22. Hasil dari training menunjukkan pada epoch pertama didapatkan tingkat akurasi sebesar 88%, seterusnya tingkat akurasi mengalami peningkatan hingga epoch 10 sebesar 95,4%. Dapat dilihat

pada gambar 6. Dan hasil confusion matrix yang ditampilkan pada Gambar 7.



Gambar 6. Hasil Training EfficientNetB1


Confusion Matrix					
True Labels	Blight	319	3	15	1
	Common_Rust	6	357	4	0
	Gray_Leaf_Spot	33	1	330	0
	Healthy	2	0	0	358
		Blight	Common_Rust	Gray_Leaf_Spot	Healthy
Predicted Labels					

Gambar 7. Confusion Matrix EfficientNetB1

Hasil dari model yang menggunakan arsitektur EfficientNetB1 menunjukkan hasil accuracy training sebesar 0,86 dan validation accuracy sebesar 0,82. Selain itu model mendapatkan loss training sebesar 0,34 dan validation loss sebanyak 0,50. Hasil dari training menunjukkan pada epoch pertama didapatkan tingkat akurasi sebesar 80,1%, seterusnya tingkat akurasi mengalami peningkatan hingga epoch 30 sebesar 92,7%. Dapat dilihat pada gambar 8. Dan hasil confusion matrix yang ditampilkan pada Gambar 9.



Gambar 8. Hasil Training Xception



Gambar 9. Confusion Matrix EfficientNetB1

Hasil confusion matrix dari model MobileNet, EfficientNet dan Xception pada Dilakukan perhitungan Precision, Recall, Accuracy dan F1 Score. Yang dapat dilihat pada tabel 4.

Table 4
Hasil dari precision, recall, accuracy dan F1 Score.

Model	Precision	Recall	F1 Score
MobileNet			
Blight	0.88	0.76	0.83
Common_Rust	0.96	0.96	0.96
Gray_Leaf_Spot	0.82	0.91	0.86
Healthy	0.98	0.98	0.98
Accuracy			0.91
EfficientNetB1			
Blight	0.89	0.94	0.91
Common_Rust	0.99	0.97	0.98
Gray_Leaf_Spot	0.85	0.91	0.93
Healthy	1.00	0.99	1.00
Accuracy			0.95
Xception			
Blight	0.70	0.72	0.71
Common_Rust	0.93	0.90	0.92
Gray_Leaf_Spot	0.76	0.77	0.77
Healthy	0.90	0.90	0.90
Accuracy			0.83

Berdasarkan hasil penelitian yang didapat tentang klasifikasi penyakit daun jagung menggunakan metode Lightweight Convolutional Neural Network dan kombinasi teknik Random oversampling yang telah dilakukan, dengan menggunakan tiga model Transfer learning MobileNet, EfficientNetB1 dan Xception serta Optimizer Adam di setiap modelnya mendapatkan akurasi 91% untuk model MobileNet, akurasi 95% untuk model EfficientNetB1 dan akurasi 83% untuk model Xception. Dapat disimpulkan untuk penelitian jaringan saraf ringan serta kombinasi resampling,

model transfer learning yang paling tinggi sebesar 95% yang di peroleh dari model EfficientNetB1 daripada model Transfer Learning lainnya.

5. Simpulan

Serta saran untuk penelitian selanjutnya atau pengembangan dari metode penelitian ini karena masih banyak kekurangan dari berbagai segi Explorasi Metode Pemrosesan Data Lanjutan dan Analisis lebih mendalam tentang Pengaruh Random Oversampling. Diharapkan penelitian selanjutnya dapat menginvestigasi penggunaan teknik pemrosesan data lanjutan seperti augmentasi data dengan variasi transformasi geometri pada citra daun jagung dan dapat melakukan analisis yang lebih rinci terkait pengaruh teknik Random Oversampling terhadap kinerja model.

Daftar Pustaka

- Arikunto, Suharsini. 1998. *Metodologi Penelitian Kualitatif*. Jakarta: Gramedia.
- Azizah, Qudsiah Nur. 2023. "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet." *Sudo Jurnal Teknik Informatika* 2(1):28–33. doi: 10.56211/sudo.v2i1.227.
- Bock, Sebastian, and Martin Weis. 2019. "A Proof of Local Convergence for the Adam Optimizer." *Proceedings of the International Joint Conference on Neural Networks 2019-July(July):1–8*. doi: 10.1109/IJCNN.2019.8852239.
- Danon, Dov, Moab Arar, Daniel Cohen-Or, and Ariel Shamir. 2021. "Image Resizing by Reconstruction from Deep Features." *Computational Visual Media* 7(4):453–66. doi: 10.1007/s41095-021-0216-x.
- Dollár, Piotr, Mannat Singh, and Ross Girshick. 2021. "Fast and Accurate Model Scaling." *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* 924–32. doi: 10.1109/CVPR46437.2021.00098.
- Dong, Shi, Ping Wang, and Khushnood Abbas. 2021. "A Survey on Deep Learning and Its Applications." *Computer Science Review* 40:100379. doi: 10.1016/j.cosrev.2021.100379.
- Dr.A, Usha Ruby. 2020. "Binary Cross Entropy with Deep Learning Technique for Image Classification." *International Journal of Advanced Trends in Computer Science and Engineering* 9(4):5393–97. doi: 10.30534/ijatcse/2020/175942020.
- Gu, Minghong, Yuejun Zhang, Yongzhong Wen, Guangpeng Ai, Huihong Zhang, Pengjun Wang, and Guoqing Wang. 2023. "A Lightweight Convolutional Neural Network Hardware Implementation for Wearable Heart Rate Anomaly Detection." *Computers in Biology and Medicine* 155:106623. doi: https://doi.org/10.1016/j.combiomed.2023.

- 106623.
- Hasnain, Muhammad, Muhammad Fermi Pasha, Imran Ghani, Muhammad Imran, Mohammed Y. Alzahrani, and Rahmat Budiarto. 2020. "Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking." *IEEE Access* 8:90847–61. doi: 10.1109/ACCESS.2020.2994222.
- James, Gareth, Daniela Witten, Trevor Hastie, and Robert Tibshirani. 2013. "Resampling Methods." Pp. 175–201 in *An Introduction to Statistical Learning: with Applications in R*. New York, NY: Springer New York.
- Khushi, Matloob, Kamran Shaukat, Talha Mahboob Alam, Ibrahim A. Hameed, Shahadat Uddin, Suhuai Luo, Xiaoyan Yang, and Maranatha Consuelo Reyes. 2021. "A Comparative Performance Analysis of Data Resampling Methods on Imbalance Medical Data." *IEEE Access* 9:109960–75. doi: 10.1109/ACCESS.2021.3102399.
- Lin, Min, Qiang Chen, and Shuicheng Yan. 2014. "Network in Network." *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings* 1–10.
- Liu, Bingyan, Yifeng Cai, Yao Guo, and Xiangqun Chen. 2021. "TransTailor: Pruning the Pre-Trained Model for Improved Transfer Learning." *35th AAAI Conference on Artificial Intelligence, AAAI 2021* 10A:8627–34. doi: 10.1609/aaai.v35i10.17046.
- Liu, Jia, Quan Zhou, Yong Qiang, Bin Kang, Xiaofu Wu, and Baoyu Zheng. 2020. "FDDWNET : A LIGHTWEIGHT CONVOLUTIONAL NEURAL NETWORK FOR REAL-TIME SEMANTIC SEGMENTATION National Engineering Research Center of Communications and Networking , School of Internet of Things , Nanjing University of Posts & Telecommunications , P . R . Chin." *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* 2373–77.
- Niu, Zhaoyang, Guoqiang Zhong, and Hui Yu. 2021. "A Review on the Attention Mechanism of Deep Learning." *Neurocomputing* 452:48–62. doi: 10.1016/j.neucom.2021.03.091.
- Peng, Han, Weikang Gong, Christian F. Beckmann, Andrea Vedaldi, and Stephen M. Smith. 2021. "Accurate Brain Age Prediction with Lightweight Deep Neural Networks." *Medical Image Analysis* 68:101871. doi: 10.1016/j.media.2020.101871.
- Rianto P, and Harjoko A. 2017. "Penentuan Kematangan Buah Salak Pondoh Di Pohon Berbasis Pengolahan Citra Digital." *IJCCS : Indonesian Journal of Computing and Cybernetics Systems* 11(2):143–54.
- Rochman Fadlur, Junaedi Hartarto. 2020. "No Title." *IMPLEMENTASI TRANSFER LEARNING UNTUK IDENTIFIKASI ORDO TUMBUHAN MELALUI DAUN* Vol. 1 No.
- Rosadi, Muhammad Imron, Moch Lutfi, and Sejarah Artikel. n.d. "Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model INFO ARTIKEL ABSTRAK." doi: 10.35891/explorit.
- Sarkar, Dipanjan, Raghav Bali, and Tamoghna Ghosh. 2018. *Hands-On Transfer Learning with Python: Implement Advanced Deep Learning and Neural Network Models Using TensorFlow and Keras*. Packt Publishing Ltd.
- Shin, Kyoham, Jongmin Han, and Seokho Kang. 2021. "MI-MOTE: Multiple Imputation-Based Minority Oversampling Technique for Imbalanced and Incomplete Data Classification." *Information Sciences* 575:80–89. doi: <https://doi.org/10.1016/j.ins.2021.06.043>.
- Singh D, Jain N, Jain P, Kayal P, Kumawat S, Batra N. PlantDoc. 2021. "Corn or Maize Leaf Disease Dataset." Retrieved (<https://www.kaggle.com/datasets/smaranjithose/corn-or-maize-leaf-disease-dataset>).
- Spectrogram, Mel, and Transfer Learning. 2022. "INTISARI Audio-Visual Convolutional Neural Networks Menggunakan Transfer Learning Untuk Deteksi Iklan Pada Video Siaran TV Audio-Visual Convolutional Neural Networks Using Transfer Learning for Commercial Break Detection in Video Broadcasting TV." 2–3.
- Sulistiyono, Mulia, Yoga Pristyanto, Sumarni Adi, and Gagah Gumelar. 2021. "Implementasi Algoritma Synthetic Minority Over-Sampling Technique Untuk Menangani Ketidakseimbangan Kelas Pada Dataset Klasifikasi." *Sistemasi* 10(2):445. doi: 10.32520/stmsi.v10i2.1303.
- Tugrul, Bulent, Elhoucine Elfatimi, and Recep Eryigit. 2022. "Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review." *Agriculture* 12(8):1192. doi: 10.3390/agriculture12081192.
- Ustyannie, Windyaning, and S. Suprpto. 2020. "Oversampling Method To Handling Imbalanced Datasets Problem in Binary Logistic Regression Algorithm." *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)* 14(1):1. doi: 10.22146/ijccs.37415.