

# ANALISIS PERFORMA INCEPTIONV3 CONVOLUTIONAL NETWORK PADA KLASIFIKASI VARIETAS DAUN GRAPEVINE

## Performance Analysis of InceptionV3 Convolutional Network Used for Grapevine Leaves Varieties Classification

Nurul Huda<sup>1</sup>, Adiyah Mahiruna<sup>2</sup>, Wellie Sulistijanti<sup>3</sup>, Rina Chandra Noor Santi<sup>4</sup>

<sup>1,2,3</sup> Institut Teknologi Statistika dan Bisnis Muhammadiyah Semarang Jl. Prof Dr.Hamka KM.1 Ngaliyan Kota Semarang Jawa Tengah, <sup>4</sup>Universitas Stikubank Semarang Jl. Tri Lomba Juang Mugassari Kota Semarang Jawa Tengah

[Nurul.huda@itesa.ac.id](mailto:Nurul.huda@itesa.ac.id), [adiyah.mahiruna@itesa.ac.id](mailto:adiyah.mahiruna@itesa.ac.id), [wellie.sulistijanti@itesa.ac.id](mailto:wellie.sulistijanti@itesa.ac.id), [r\\_chandra\\_ns@edu.unisbank.ac.id](mailto:r_chandra_ns@edu.unisbank.ac.id)

### ABSTRAK

Daun Grapevine digunakan dalam berbagai masakan tradisional di seluruh dunia. Mengenali berbagai jenis daun Grapevine menjadi semakin penting karena harga dan rasanya bervariasi. Akan tetapi, identifikasi jenis daun ini secara manual akan sulit dan membutuhkan waktu yang lama. Sehingga, beberapa penelitian tentang klasifikasi daun ini dilakukan dengan memanfaatkan metode *machine learning*. Penelitian ini bertujuan untuk mengklasifikasikan 5 jenis daun Grapevine menggunakan arsitektur InceptionV3 yang merupakan salah satu arsitektur Convolutional Neural Network (CNN). Dataset yang digunakan adalah dataset publik yang terdiri dari 500 gambar, dimana untuk masing-masing kelas terdiri dari 100 gambar yaitu Ak (100), Ala Idris (100), Buzgulu (100), Dimnit (100), Nazli (100). Tahapan pertama dari penelitian ini dengan cara membagi dataset menjadi data training dan data testing. Persentase data training sebesar 80% (400 gambar) dan data testing 20% (100 gambar). Tahapan selanjutnya dengan melakukan *preprocessing* gambar, dimulai dengan augmentasi gambar kemudian merubah ukuran gambar menjadi 300x300 pixel. Hasil dari *preprocessing* gambar inilah yang digunakan untuk uji coba model. Jika peneliti sebelumnya mengusulkan model berbasis Densenet-30 dan menghasilkan akurasi 98%, penelitian ini dengan menggunakan model InceptionV3 Convolutional Network berhasil mencapai akurasi sebesar 99.5%.

**Kata kunci:** *varietas daun grapevine, InceptionV3, Klasifikasi, Image Processing*

### ABSTRACT

Grapevine leaves are used in various traditional dishes around the world. Recognizing the different types of grapevine leaves is becoming increasingly important as prices and tastes vary. However, identifying this type of leaf manually would be difficult and would take a long time. Thus, several studies on leaf classification were carried out by utilizing the machine learning method. This study aims to classify 5 types of grapevine leaves using the InceptionV3 architecture, which is one of the Convolutional Neural Network (CNN) architectures. The dataset used is a public dataset consisting of 500 images, where each class consists of 100 images namely Ak (100), Ala Idris (100), Buzgulu (100), Dimnit (100), Nazli (100). The first stage of this research is by dividing the dataset into training data and testing data. The percentage of training data is 80% (400 images) and 20% testing data (100 images). The next step is to do image pre-processing, starting with image augmentation and then resizing the image to 300x300 pixels. The results of this image pre-processing are used for model testing. If the previous researcher proposed a Densenet-30 based model and produced an accuracy of 98%, this research using the InceptionV3 Convolutional Network model managed to achieve an accuracy of 99.5%.

**Keywords:** *grapevine leaves varieties, InceptionV3, Classification, Image Processing*

### Pendahuluan

Karena keragaman spesiesnya, identifikasi daun merupakan bidang penelitian yang menarik.

Daun sering digunakan untuk mengidentifikasi tanaman karena menyediakan berbagai data yang tersedia dalam koleksi referensi botani

dan paling mudah diperoleh dalam penyelidikan lapangan. Daun tanaman lebih baik diklasifikasikan karena daun dapat mengidentifikasi sifat spesifik tanaman. Daun *grapevine* sering digunakan dalam masakan tradisional, varietas dan harganya beragam dan sulit dibedakan secara kasat mata. Sehingga identifikasi menggunakan metode *machine learning*, dianggap dapat menyelesaikan permasalahan tersebut. Untuk mengklasifikasikan daun anggur, digunakan model CNN DenseNet-30 berdasarkan dataset publik yang terdiri dari 500 gambar dengan 5 kelas berbeda. Selain itu metode augmentasi seperti flip horizontal, flip vertical, pertajam kontras, kecerahan acak, dan pertajam gambar dilakukan untuk menambah data training. Model ini mencapai akurasi 98% (Ahmed et al., 2023). Daun anggur diduga kaya akan senyawa bioaktif dan protein, sehingga penelitian varietas daun anggur perlu lebih dikembangkan lagi (Banjanin et al., 2021).

Klasifikasi daun tanaman merupakan langkah kunci untuk memecahkan masalah umum seperti klasifikasi jenis, estimasi pertumbuhan, dan prediksi kesehatan. Algoritma otomatisasi klasifikasi tanaman berdasarkan daunnya merupakan cara untuk mepercepat identifikasi. Algoritma klasifikasi daun untuk membedakan tanaman memiliki tiga tahap yaitu pre-prosesan, ekstraksi fitur, dan klasifikasi. Pada tahap pre-processing, daun disegmentasi dari background menggunakan segmentasi warna kemudian dinormalisasi. Fitur yang diekstraksi meliputi morfologi, Fourier Descriptor (FD), dan Shape Defining Features (SDF). Fitur-fitur tersebut merupakan input vektor dalam jaringan syarat tiruan (JST) pada tahap klasifikasi. Hasil penelitian menunjukkan akurasi 96% untuk klasifikasi 817 sampel daun dari 14 pohon buah yang berbeda (Aakif & Khan, 2015). Penyajian pendekatan baru untuk mendeteksi dan mendiagnosa daun mangga pernah dilakukan, dengan menggunakan model klasifikasi VGGnet dan beberapa fitur seperti warna daun, venasi, kondisi tangkai daun,

bentuk ujung, kondisi ujung, bentuk daun, tepi daun, bercak hitam pada helai daun dan pelepas, tepi luka bakar pada daun, helai daun, pelepas, serta tangkai daun, menghasilkan akurasi klasifikasi sebesar 92% (Venkatesh et al., 2020). Selain itu, metode deep learning juga dilakukan untuk klasifikasi kultivar daun kedelai, hasilnya menunjukkan akurasi sebesar 69,2% untuk model ResNet34 (You, 2021).

Untuk membantu dalam identifikasi dan klasifikasi penyakit daun anggur menggunakan Convolutional Neural Network (CNN). Makalah ini bertujuan untuk memudahkan petani dalam mengidentifikasi tanaman merambat dan mengatasi penyakit anggur dengan lebih cepat. Implementasi CNN pada penelitian ini menggunakan library Keras yang menggunakan bahasa pemrograman python. Proses pelatihan CNN menggunakan learning rate 0,0001 diperoleh hasil dengan tingkat akurasi sebesar 91,37% (Hasan et al., 2020).

Pendekatan pembelajaran mendalam menggunakan pembelajaran ansambel berdasarkan tiga arsitektur Convolutional Neural Network (CNN) yang terkenal (Visual Geometry Group (VGG16), VGG19, dan Extreme Inception (Xception)) untuk klasifikasi penyakit daun anggur. Model yang diusulkan dilatih sebelumnya dengan ImageNet dan dianalisis menggunakan kumpulan data Plant Village (PV) dari penyakit daun anggur yang umum (Nader et al., 2022).

Penelitian tentang klasifikasi varietas daun anggur menggunakan model DenseNet-30 menunjukkan hasil akurasi terbaik yaitu 98%, didalam penelitian ini akan menggunakan dataset yang sama dengan penelitian sebelumnya akan tetapi menggunakan metode yang berbeda, yaitu InceptionV3 diharapkan mencapai akurasi yang lebih baik.

## Metode

CNN model dikenal memberikan akurasi terbaik jika digunakan pada dataset berupa gambar. Dikarenakan penelitian ini juga

menggunakan dataset gambar, maka metode CNN dipilih dalam penelitian ini.

- **Dataset**

Dalam penelitian ini, daun grapevine yang digunakan merupakan dataset publik (Ahmed et al., 2023). Dataset terdiri dari 5 jenis varietas daun grapevine yaitu “Ak”, “Ala Idris”, “Buzgulu”, “Dimnit”, dan “Nazli”. Masing-masing varietas terdiri dari 100 gambar dengan resolusi 512x512 pixel. Sehingga jumlah keseluruhan gambar menjadi 500 gambar. Gambar 1 adalah sampel gambar dari masing-masing varietas.

- **InceptionV3 Convolutional Network**

Inception architecture adalah model jaringan terlatih yang dikenal sebagai GoogleNet pada tahun 2014 (He et al., 2016). InceptionV3 adalah arsitektur deep learning generasi ke-3 yang dikembangkan oleh google (Szegedy et al., 2016). Metode faktorisasi digunakan dalam Inception V3. Strategi ini meminimalkan jumlah parameter dan koneksi untuk meningkatkan kinerja jaringan pembelajaran yang mendalam. Jaringan deep learning V3 awal terdiri dari berbagai struktur seperti pooling rata-rata, pooling maksimum, dropout, concats, convolutions, dan lapisan FC (Çakmak, 2023).

- **Model**

Augmentasi data dapat digunakan untuk memecahkan masalah overfitting pada tahap pelatihan CNN. Masalah overfitting dalam model deep learning terjadi ketika random noise banyak terjadi dalam dataset yang digunakan. Dengan lebih banyak gambar setelah augmentasi data, model dapat mempelajari sebanyak mungkin pola yang tidak relevan selama fase pelatihan, mengurangi overfitting, dan meningkatkan kemampuan anti-interferensi dalam pengaturan yang kompleks (Liu et al., 2020). Untuk memperkuat kumpulan data, augmentasi mungkin melibatkan penyesuaian kecil pada data atau penggunaan model pembelajaran mesin

untuk menghasilkan titik data baru di ruang laten dari data asli (Binnar & Sharma, 2023). Dalam penelitian ini, augmentasi gambar dilakukan menggunakan tools *ImageDataGenerator Class* dari Keras Deep Learning Package (V2.4.3). Augmentasi data meliputi: horizontal dan vertical flip, rotasi, shear, width dan height shift, zoom, dan fill mode (Alessandrini et al., 2021). langkah-langkah penelitian adalah sebagai berikut:

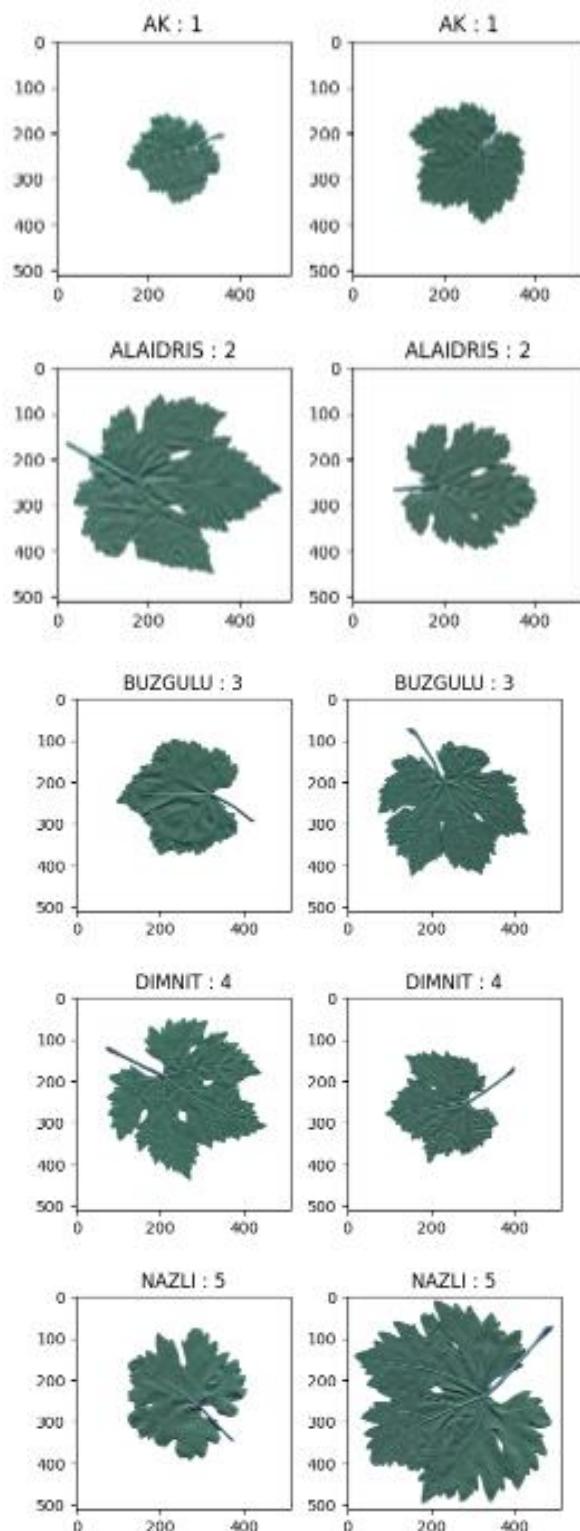
1. Download dataset dari Kaggle: pada Langkah ini data langsung di download dari repository Kaggle yaitu “Grapevine Leaves Image Dataset”, kemudian disimpan di lokal path.
2. Original Dataset berisi 5 kelas gambar dengan ukuran 512x512 pixel sebanyak 500 gambar.
3. ResNet50 CNN arsitektur sebagai jaringan backbone, banyak digunakan dan berkinerja baik di bidang klasifikasi gambar (Li et al., 2022). Akan tetapi penelitian ini memilih arsitektur InceptionV3. CNN model membutuhkan data training yang banyak untuk hasil yang maksimal, sehingga pre-processing data dilakukan. Tahapan pre-processing data dapat dilihat pada tabel 1.
4. Hasil dari pre-processing data akan menjadi file input untuk proses training dan testing model.
5. Model machine learning yang digunakan pada penelitian ini adalah “InceptionV3 Convolutional Network”. Arsitektur model konvolusi ditunjukkan pada gambar 2.

Secara garis besar tahapan penelitian ditunjukkan pada gambar 3.

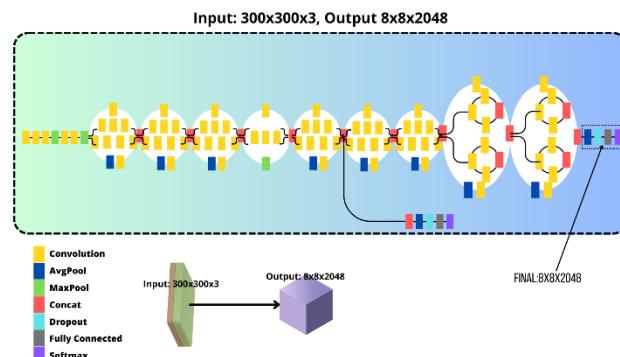
**Tabel 1. Konsistensi Dataset**

Class	Size	Resize	Jumlah	Jumlah	Augmentasi
Ak	512x512	300x300	100	900	
Ali Idris	512x512	300x300	100	900	

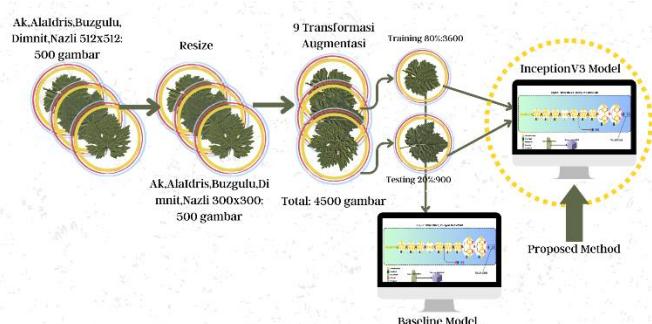
Buzgulu	512x512	300x300	100	900
Dimnit	512x512	300x300	100	900
Nazli	512x512	300x300	100	900
Total			500	4500



**Gambar 1. Varietas Daun Grapevine**



**Gambar 2. InceptionV3 Arsitektur Model**



**Gambar 3. Proposed Method**

## Hasil Dan Pembahasan

Hasil implementasi metode yang diusulkan akan dibahas pada bagian ini. Terdapat beberapa cara untuk evaluasi model, diantaranya performance accuracy, F1-Score, Precision, Recall, Training Loss, dan waktu yang dibutuhkan per epoch (Hassan et al., 2021). Selain itu untuk memudahkan membaca hasil penelitian umumnya peneliti akan akan menggambarkan kurva ROC yang merupakan visualisasi dari training dan validasi loss (Binnar & Sharma, 2023). Selain itu performa hasil penelitian juga perlu disajikan dalam bentuk tabel komparasi antara peneliti sebelumnya dengan menggunakan metode yang berbeda, seperti misalnya membandingkan peneliti sebelumnya, metode saat ini A, dan metode saat ini B (Bharate & Shirdhonkar, 2020).

Hasil penelitian ini disajikan pada tabel 2. Didalam tabel dijelaskan bahwa penelitian

sebelumnya menghasilkan akurasi 98%, sedangkan penelitian baseline model mencapai akurasi hanya 25,99 %, dan metode yang diusulkan dalam penelitian ini yaitu InceptionV3 Convolutional Network meraih akurasi 99,5%.

**Tabel 2. Perbandingan Hasil Penelitian**

Parameter	Earlier (Ahmed et al., 2023)	Baseline Model	InceptionV3 Models
Dataset	500 Grapevine Leaves	500 Grapevine Leaves	500 Grapevine Leaves
Classifier	CNN DenseNet-30	Sequential CNN No Augmentation	Convolutionnal Network with Augmentation
Number of Sample	After Augmentation 2800 image	No augmentation 500 dataset	After Augmentation 4500 dataset
Parameters	Not described	After konvolusi (300x300x3) : 362.629	After konvolusi (300x300x3) : 23,117,093
Akurasi	98%	25,99%	99,5%

dari tabel diatas menunjukkan bahwa jumlah dataset dan parameter yang digunakan sebagai input data dalam machine learning sangat mempengaruhi performa akurasi. Semakin banyak data dan parameter yang digunakan maka akurasi akan semakin tinggi. Selain itu didalam CNN semakin banyak epoch, maka akurasi akan semakin baik, akan tetapi hal ini harus didukung dengan adanya spesifikasi komputer yang memadai. Menjalankan program dari GPU dibandingkan CPU akan mempengaruhi lamanya waktu proses komputasi per epoch. Spesifikasi komputer yang digunakan dalam penelitian ini disajikan pada tabel3.

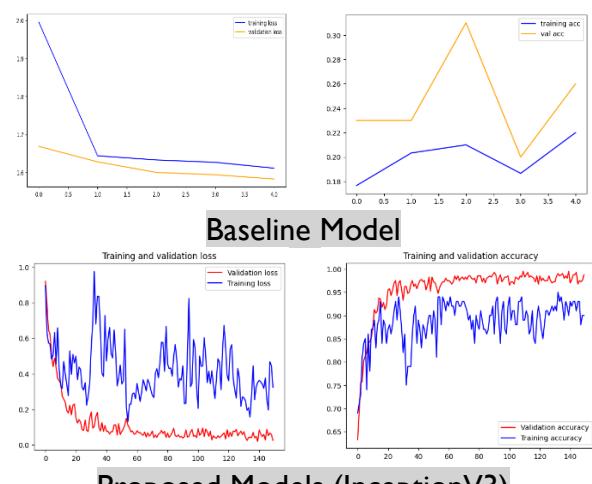
**Tabel 3. Spesifikasi Komputer yang digunakan**

Type	Detail
Type Laptop	Asus TUF Gaming F15
Processor	Core™ i7-12700H
Memory	16GB 4800MHz DDR5 RAM
GPU	Up to NVIDIA® GeForce RTX™ 3070

SSD	Up to 1TB SSD NVMe® PCIe®
OS	Windows 11 Home

Sedangkan software yang digunakan dalam penelitian ini adalah jupyter notebook dan python 3.11.

Dengan spesifikasi tersebut diatas, grafik ROC training loss dan validation loss dari baseline model dan proposed model ditunjukkan pada gambar 4.



**Gambar 4. Grafik Baseline dan Proposed Model**

Dalam tahapan training baseline model, digunakan 5 epoch dimana step per epoch adalah 3, akurasi tertinggi terjadi pada epoch ke-5 (22%) dengan uji parameter sebanyak 362.629. Sedangkan model InceptionV3 menggunakan input shape 300x300x3 sehingga dihasilkan 23.117.093 parameter sebagai data input. Saat validasi digunakan 150 epoch dan tiap step terdiri dari 4 epoch. Akurasi tertinggi terjadi pada epoch ke-110 (99,5%). Sedangkan rata-rata waktu komputasi adalah 29 detik per epoch.

### Simpulan dan Saran

Model yang diusulkan dalam penelitian ini berhasil mencapai akurasi yang lebih baik dibandingkan model sebelumnya. Akan tetapi penelitian ini hanya menggunakan 1 macam

dataset saja, sehingga performa akurasi terbatas dan belum tentu menghasilkan akurasi yang sama jika digunakan pada dataset daun anggur yang lainnya. Selain itu penelitian ini hanya mengusulkan 1 model arsitektur CNN yaitu InceptionV3, belum membandingkan performa machine learning dengan arsitektur CNN lainnya. Kedepan, penelitian dapat dikembangkan lebih lanjut menggunakan dataset yang lebih variatif dan beberapa arsitektur model diterapkan untuk evaluasi hasil.

### Pustaka Acuan

- Aakif, A., & Khan, M. F. (2015). Automatic classification of plants based on their leaves. *Biosystems Engineering*, 139, 66–75. <https://doi.org/10.1016/j.biosystemseng.2015.08.003>
- Ahmed, H. A., Hama, H. M., Jalal, S. I., & Ahmed, M. H. (2023). Deep Learning in Grapevine Leaves Varieties Classification Based on Dense Convolutional Network. *Journal of Image and Graphics*, 11(1), 98–103. <https://doi.org/10.18178/joig.11.1.98-103>
- Alessandrini, M., Calero Fuentes Rivera, R., Falaschetti, L., Pau, D., Tomaselli, V., & Turchetti, C. (2021). A grapevine leaves dataset for early detection and classification of esca disease in vineyards through machine learning. *Data in Brief*, 35, 106809. <https://doi.org/10.1016/j.dib.2021.106809>
- Banjanin, T., Uslu, N., Vasic, Z. R., & Özcan, M. M. (2021). Effect of grape varieties on bioactive properties, phenolic composition, and mineral contents of different grape-vine leaves. *Journal of Food Processing and Preservation*, 45(2), 0–2. <https://doi.org/10.1111/jfpp.15159>
- Bharate, A. A., & Shirdhonkar, M. S. (2020). Classification of Grape Leaves using KNN and SVM Classifiers. *Proceedings of the 4th International Conference on Computing Methodologies and Communication, ICCMC 2020, Iccmc*, 745–749.
- <https://doi.org/10.1109/ICCMC48092.2020.901CCMC-000139>
- Binnar, V., & Sharma, S. (2023). Plant Leaf Diseases Detection Using Deep Learning Algorithms. *Lecture Notes in Electrical Engineering*, 946(1), 217–228. [https://doi.org/10.1007/978-981-19-5868-7\\_17](https://doi.org/10.1007/978-981-19-5868-7_17)
- Çakmak, M. (2023). *Grapevine Leaves Classification using Transfer Learning and Fine Tuning*.
- Hasan, M. A., Riana, D., Swasono, S., Priyatna, A., Pudjiarti, E., & Prahartiwi, L. I. (2020). Identification of Grape Leaf Diseases Using Convolutional Neural Network. *Journal of Physics: Conference Series*, 1641(1). <https://doi.org/10.1088/1742-6596/1641/1/012007>
- Hassan, S. M., Maji, A. K., Jasiński, M., Leonowicz, Z., & Jasińska, E. (2021). Identification of plant-leaf diseases [1] S. M. Hassan, A. K. Maji, M. Jasiński, Z. Leonowicz, and E. Jasińska, “Identification of plant-leaf diseases using cnn and transfer-learning approach,” *Electron.*, vol. 10, no. 12, 2021, doi: 10.3390/electronics101213. *Electronics (Switzerland)*, 10(12).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Li, H., Wei, Y., Zhang, H., Chen, H., & Meng, J. (2022). Fine-grained classification of grape leaves via a pyramid residual convolution neural network. *International Journal of Agricultural and Biological Engineering*, 15(2), 197–203. <https://doi.org/10.25165/j.ijabe.20221502.6894>
- Liu, B., Ding, Z., Tian, L., He, D., Li, S., & Wang, H. (2020). Grape Leaf Disease Identification Using Improved Deep

- Convolutional Neural Networks. *Frontiers in Plant Science*, 11(July), 1–14.  
<https://doi.org/10.3389/fpls.2020.01082>
- Nader, A., Khafagy, M. H., & Hussien, S. A. (2022). Grape Leaves Diseases Classification using Ensemble Learning and Transfer Learning. *International Journal of Advanced Computer Science and Applications*, 13(7), 563–571.  
<https://doi.org/10.14569/IJACSA.2022.0130767>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, 2818–2826.  
<https://doi.org/10.1109/CVPR.2016.308>
- Venkatesh, Nagaraju, Y., Sahana, T. S., Swetha, S., & Hegde, S. U. (2020). Transfer Learning based Convolutional Neural Network Model for Classification of Mango Leaves Infected by Anthracnose. *2020 IEEE International Conference for Innovation in Technology, INOCON 2020*.  
<https://doi.org/10.1109/INOCON50539.2020.9298269>
- You, J. (2021). Leaf Image Classification Using Deep Learning Network. *Academic Journal of Computing & Information Science*, 4(3), 109–115.  
<https://doi.org/10.25236/ajcis.2021.040317>