

# ***Penerapan CNN Untuk Klasifikasi Tingkat Kematangan Berry Dengan Augmentasi Transformasi Dan Colorjitter Menggunakan Tensorflow***

Oleh:

**Vieri Lusen, Intan Purnamasari, dan Betha Nurina Sari**

Universitas Singaperbangsa Karawang, Indonesia

Email: [vieri.lusen17210@student.unsika.ac.id](mailto:vieri.lusen17210@student.unsika.ac.id)

## ***Abstract***

*With the increasing consumer demand for fresh and high-quality fruits, automated recognition of fruit ripeness becomes crucial to enhance the quality and efficiency in fruit production. This research focuses on the implementation of Convolutional Neural Network (CNN) with Transformation Augmentation and Color Jitter using TensorFlow to classify the ripeness level of berries through images. The dataset consists of images of berries that have undergone pre-processing steps, including resizing images to 224x224 pixels, horizontal flipping, a rotation range of 20 degrees, zoom range of 0.3, shear range of 0.3, height shift range of 0.3, width shift range of 0.3, random hue of 0.08, random saturation of 0.6-1.6, random brightness of 0.05, and random contrast of 0.7-1.3. The network architecture comprises 4 convolution layers, 4 max-pooling layers, a global average pooling layer, and a dense layer. The results show that the CNN method with Transformation Augmentation and Color Jitter using TensorFlow can achieve good accuracy in classifying the ripeness of berries. After 500 epochs of training, the model achieved an accuracy of 93.75% on the training data and 90.33% on the testing data. The model also achieved 100% accuracy on 30 new data samples that were different from the training and testing data. Additionally, the use of Transformation Augmentation and Color Jitter in CNN has a positive impact on the accuracy of ripeness classification of berries, with the augmented model showing higher accuracy.*

**Keywords:** *Berry Fruits, Digital Image Processing, Machine Learning, Tensorflow, AI, Augmentasi Transformasi, Color Jitter.*

## **A. Pendahuluan**

Industri pertanian mengalami perkembangan pesat seiring dengan kemajuan zaman. Indonesia, dengan iklim tropis, curah hujan tinggi, dan tanah subur, memiliki potensi besar dalam produksi pangan, terutama buah-buahan. Buah tidak hanya menjadi sumber pangan, tetapi juga bermanfaat bagi kesehatan dan lingkungan. Buah menyediakan nutrisi, vitamin, serat, energi, antioksidan, dan berbagai senyawa yang dibutuhkan tubuh untuk pemenuhan gizi serta pencegahan dan pengobatan penyakit. Selain itu, buah berperan penting dalam ekonomi sebagai sumber pendapatan di sektor pertanian, perdagangan, dan industri. Salah satu buah yang kaya manfaat dan sering dikonsumsi masyarakat adalah buah jenis berry.

Buah berry tidak hanya bermanfaat bagi kesehatan, tetapi juga berpotensi meningkatkan perekonomian Indonesia. Buah berry berpotensi menjadi komoditas ekspor

karena bisa diproduksi sepanjang tahun di Indonesia<sup>1</sup>. Saat negara lain mengalami off-season, Indonesia dapat menyuplai buah berry ke negara-negara tersebut. Harga buah berry relatif stabil dan cenderung naik, berbeda dengan komoditas pertanian lainnya yang mengalami penurunan harga saat panen melimpah. Pasokan buah berry berkurang sekitar 50% saat musim hujan, sehingga harganya naik di tengah tingginya permintaan. Kualitas buah berry juga lebih baik saat musim kemarau, menjaga harga tetap tinggi. Potensi ini dapat meningkatkan taraf hidup petani dan mengurangi impor buah berry ke pasar lokal.

Dengan banyaknya manfaat dan potensi dari buah berry, diperlukan model yang dapat mengenali klasifikasi kematangan buah berry untuk memaksimalkan kualitas dan daya tarik pasar. Kematangan buah berry memengaruhi rasa, tekstur, warna, kandungan nutrisi, dan umur simpan, sehingga penting untuk memahami dan mengelola proses kematangan dengan baik. Permintaan konsumen akan produk buah segar dan berkualitas juga terus meningkat. Dengan kemampuan komputasi yang memungkinkan komputer mengambil informasi dari citra digital secara otomatis, diharapkan model ini dapat menjadi solusi dalam klasifikasi kematangan buah berry. Penerapan model ini di masa depan dapat meningkatkan produksi berkualitas di lahan perkebunan yang luas, termasuk sistem pemilihan buah otomatis, pemantauan tanaman efisien, dan proses terkait lainnya dalam klasifikasi kematangan buah berry.

Salah satu metode yang dapat digunakan untuk pengolahan citra adalah *Convolutional Neural Network* (CNN). CNN adalah algoritma *Deep Learning* yang mampu mengambil data dari gambar, mengenali kepentingan seperti bias dan bobot yang dapat dipelajari dalam berbagai aspek atau objek dalam gambar, dan membedakan gambar satu dengan yang lainnya<sup>2</sup>. Untuk meningkatkan nilai akurasi, dapat dilakukan data augmentasi pada tahap *pre-processing*. Salah satu metode data augmentasi yang berguna adalah Augmentasi Transformasi dan *Color Jitter*. Metode ini mengubah bentuk gambar dan memberikan nilai warna secara acak, bertujuan untuk memperbanyak dan memberikan variasi pada dataset. Salah satu cara menerapkan metode CNN adalah dengan menggunakan framework. Ada banyak framework yang telah dikembangkan untuk *deep learning*, dan salah satunya adalah *TensorFlow*, yang dapat digunakan untuk menerapkan CNN. Dengan latar belakang ini, peneliti akan menerapkan metode CNN dengan *Color Jitter* menggunakan *TensorFlow* sebagai salah satu langkah dalam klasifikasi kematangan buah berry. Jenis buah *berry* yang akan dideteksi adalah *blueberries* dan *strawberries*.

---

<sup>1</sup> Dani, "Budidaya Blackberry, Blueberry dan Raspberry Untung hingga 65%", 2019.

<sup>2</sup> Sumit Saha, "A Comprehensive Guide to Convolutional Neural Networks", 2018.

## B. Pembahasan

### 1. Kajian Teori

Beberapa kajian yang sudah digali terkait teori-teori atau *tech stack* dalam penelitian ini mengacu pada kebutuhan penerapan CNN dalam klasifikasi kematangan buah berry.

#### a. Citra Digital

Sebuah citra digital dapat dipahami sebagai suatu representasi dalam bentuk matriks dengan M kolom dan N baris, di mana setiap titik perpotongan antara kolom dan baris disebut piksel. Piksel, sebagai elemen terkecil dari citra, mengandung dua informasi kunci, yaitu koordinat dan nilai warna atau intensitas. Informasi intensitas atau warna dari setiap piksel dapat ditelusuri pada koordinat  $f(x,y)$  dari piksel tersebut<sup>3</sup>.

#### b. Pengolahan Citra Digital

Pengolahan citra adalah suatu rangkaian proses yang bertujuan untuk merubah atau memodifikasi citra agar memiliki kualitas yang lebih baik dari sebelumnya, menggunakan bantuan komputer<sup>4</sup>. Tujuan utama dari pengolahan citra adalah agar citra tersebut dapat lebih mudah diinterpretasi dan dipahami oleh manusia maupun mesin, serta dapat digunakan secara efektif dalam berbagai aplikasi seperti pengenalan objek, analisis medis, atau pemrosesan visual lainnya. Dengan adanya teknologi pengolahan citra, informasi yang terkandung dalam citra dapat diekstrak dengan lebih baik, memberikan nilai tambah dalam berbagai bidang, mulai dari keperluan diagnostik medis hingga pengembangan teknologi canggih dalam bidang kecerdasan buatan.

#### c. Color Jitter

Color Jitter merupakan salah satu teknik augmentasi yang mengubah properti warna pada gambar dengan memodifikasi nilai brightness, contrast, saturation, atau hue dari gambar tersebut<sup>5</sup>. Tujuan dari penerapan Color Jitter biasanya adalah untuk mensimulasikan variasi kondisi pencahayaan yang berbeda dan menghasilkan citra yang lebih bervariasi.

#### d. Deep Learning

*Deep learning* merupakan cabang dari kecerdasan buatan yang secara konseptual didasarkan pada struktur *neuron* di otak manusia, yang telah berhasil

---

<sup>3</sup> Akhmad Fadjeri, Arief Setyanto, and Mei Kurniawan “Pengolahan Citra Digital Untuk Menghitung Ekstraksi Ciri Greenbean Kopi Robusta dan Arabika (Studi Kasus: Kopi Temanggung)”, 2020, doi:10.30646/tikomsin.v8i1.462.

<sup>4</sup> Tutut Furi Kusumaningrum, “Implementasi Convolution Neural Network (CNN) untuk Klasifikasi Jamur Konsumsi Di Indonesia Menggunakan Keras”, 2018.

<sup>5</sup> Harshit Kumar, “Data augmentation Techniques”, 2024, <https://iq.opengenus.org/data-augmentation/>.

digunakan dalam berbagai bidang seperti *computer vision*, *natural language processing*, dan *robotics* untuk menyelesaikan berbagai masalah yang kompleks<sup>6</sup>. Hampir semua bidang ilmiah telah merasakan dampak dari teknologi deep learning ini. Sebagian besar industri dan bisnis telah terdampak dan berubah dengan penggunaan deep learning.

e. *Convolutional Neural Network (CNN)*

Dalam ranah *Deep Learning*, CNN merupakan algoritma yang sangat terkenal dan sering digunakan. CNN telah diimplementasikan secara luas dalam berbagai bidang, seperti *computer vision*, *speech processing*, *image recognition*, dan lainnya. Metode CNN pertama kali diusulkan dan diterapkan untuk analisis gambar berdimensi tinggi<sup>7</sup>. Struktur CNN terinspirasi oleh *neuron* dalam otak manusia dan hewan, dirancang dengan arsitektur yang terdiri dari sejumlah lapisan yang disebut *multi-building block*<sup>8</sup>.

f. *TensorFlow*

*TensorFlow* adalah perpustakaan sumber terbuka yang dikembangkan oleh tim Google Brain untuk membangun dan melatih jaringan saraf dalam *deep learning*. *Framework* ini pertama kali diluncurkan pada bulan November 2015 dan sejak itu telah menjadi salah satu perpustakaan yang paling populer digunakan dalam pengembangan model *deep learning*. *TensorFlow* memanfaatkan konsep *tensor* sebagai struktur data fundamental, yang memungkinkan pengguna untuk memodelkan berbagai jenis arsitektur jaringan saraf, mengoptimalkan model dengan berbagai *optimizer* yang tersedia, serta melakukan pelatihan secara efisien dengan dukungan akselerasi GPU<sup>9</sup>. Dukungan yang luas dari komunitas dan ekosistem yang berkembang membuat *TensorFlow* menjadi pilihan utama bagi para peneliti dan praktisi dalam mengembangkan solusi machine learning yang kompleks.

## 2. Implementasi

Pada penerapannya metode penelitian yang digunakan dalam studi ini adalah metode penelitian kuantitatif, yang menghasilkan akurasi dengan menghitung tingkat

<sup>6</sup> Zaharchuk, Gong, Wintermark, Rubin, and Langlotz, “*Deep Learning in Neuroradiology*. *American Journal of Neuroradiology*”, 2018, <https://doi.org/10.3174/ajnr.A5543>.

<sup>7</sup> Anandhavalli Muniyasamy and Areej Alasiry, “*Deep Learning: The Impact on Future eLearning*. *International Journal of Emerging Technologies*”, 2020, <https://doi.org/10.3991/ijet.v15i01.11435>.

<sup>8</sup> Laith Alzubaidi, Jinglan Zhang, Amjad J. Humaidi, Ayad Al-Dujaili, Ye Duan, Omran Al-Shamma, J. Santamaría, Mohammed A. Fadhel, Muthana Al-Amidie and Laith Farhan, “*Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*”, 2021, <https://doi.org/10.1186/s40537-021-00444-8>.

<sup>9</sup> Tran Xuan Truong, Viet-Ha Nhu, Doan Thi Nam Phuong, Le Thanh Nghi, Nguyen Nhu Hung, Pham Viet Hoa, and Dieu Tien Bui, “*A New Approach Based on TensorFlow Deep Neural Networks with ADAM Optimizer and GIS for Spatial Prediction of Forest Fire Danger in Tropical Areas*”, 2023, <https://doi.org/10.3390/rs15143458>.

kesesuaian antara input dan hasil yang diperoleh. Langkah-langkah dalam penelitian ini terbagi menjadi lima tahap, yaitu data *collection*, *pre-processing*, *modeling*, *testing*, dan *evaluation*.

a. *Data Collection*

Tahap awal penelitian ini adalah pengumpulan data dari Kaggle dan Google Images berupa gambar *blueberry* dan *strawberry* dalam format .jpg, .jpeg, atau .png. Total data terkumpul sebanyak 1500 gambar, dibagi menjadi 6 kategori: *immature blueberry* (200 gambar), *mature blueberry* (300 gambar), *rotten blueberry* (250 gambar), *immature strawberry* (200 gambar), *mature strawberry* (300 gambar), dan *rotten strawberry* (250 gambar). Data kemudian dibagi menjadi data *training* (80%) dan data *testing* (20%) untuk masing-masing kategori.

b. *Pre-processing*

Pada tahap ini, data yang telah dikumpulkan akan melalui serangkaian proses *pre-processing* untuk mempersiapkannya secara optimal sebelum digunakan dalam analisis atau model. Proses ini melibatkan berbagai modifikasi, termasuk penyesuaian ukuran (*resize*) gambar sebesar 224x224 pixel untuk memastikan konsistensi dan kesesuaian dalam struktur data. Selain itu, dilakukan juga augmentasi transformasi dan *colorjitter*, di mana bentuk dan warna gambar dapat bervariasi untuk memperkaya dataset dan meningkatkan keberagaman fitur yang dapat dipelajari oleh model. Tahap ini bertujuan memastikan bahwa data siap untuk analisis atau penggunaan dalam klasifikasi gambar.

**Gambar 1. Sample Gambar Tanpa Augmentasi dan Color Jitter**



**Gambar 2. Sample Gambar Menggunakan Augmentasi dan Color Jitter**



Sumber: dokumentasi peneliti, 2024

c. *Modeling*

Setelah *pre-processing* selesai, langkah berikutnya adalah tahap pemodelan. Pada tahap ini, model *Convolutional Neural Network* (CNN) akan dibangun dan dilatih menggunakan data *training* yang telah dipersiapkan. Untuk membuat model menggunakan *TensorFlow*, langkah pertama adalah mengimpor *models* dan *layers*

dari *library* Keras. Dengan menggunakan model *Sequential* dari Keras, kita akan mendefinisikan urutan *layer-layer* yang membentuk arsitektur model. Langkah selanjutnya adalah mengonfigurasi *layer-layer* ini untuk mencapai akurasi yang optimal, dengan model yang telah didefinisikan akan memiliki struktur arsitektur seperti berikut:

Gambar 3. Arsitektur Model

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 222, 222, 128)	3,584
max_pooling2d (MaxPooling2D)	(None, 111, 111, 128)	0
conv2d (Conv2D)	(None, 109, 109, 64)	73,792
max_pooling2d (MaxPooling2D)	(None, 54, 54, 64)	0
conv2d (Conv2D)	(None, 52, 52, 32)	18,464
max_pooling2d (MaxPooling2D)	(None, 26, 26, 32)	0
conv2d (Conv2D)	(None, 24, 24, 16)	4,624
max_pooling2d (MaxPooling2D)	(None, 12, 12, 16)	0
global_average_pooling2d (GlobalAveragePooling2D)	(None, 16)	0
dense (Dense)	(None, 6)	102
Total params:		100,566
Trainable params:		100,566
Non-trainable params:		0

Sumber: dokumentasi peneliti, 2024


#### d. Testing

Setelah pemodelan selesai, langkah selanjutnya adalah melakukan *training* dan *testing* terhadap dataset yang telah dipersiapkan sebelumnya. *Training* dan *testing* ini merupakan langkah kritis dalam mengajarkan model untuk memahami pola dan fitur pada data latih, sehingga dapat memberikan prediksi yang akurat pada data baru. Selama pelatihan, model akan melakukan komputasi matematika menggunakan fungsi kerugian (*loss function*) untuk mengukur seberapa jauh prediksi model dari nilai yang sebenarnya.

Proses ini berulang dalam beberapa *epoch*, di mana satu *epoch* mengacu pada satu kali iterasi melalui seluruh *dataset* pelatihan. Melalui *epoch-epoch* berurutan, model secara bertahap meningkatkan kemampuannya untuk memahami pola yang kompleks. Untuk melakukan pelatihan menggunakan *TensorFlow*, terdapat sebuah fungsi yang dapat digunakan yaitu fungsi *fit* model. Sebelum melakukan pelatihan dan menggunakan fungsi *fit* model, hal pertama yang harus dilakukan adalah menentukan banyaknya *epoch* atau iterasi seperti yang telah dijelaskan sebelumnya. Dalam penelitian ini, banyaknya *epoch* yang digunakan adalah sebanyak 500 *epoch* atau


iterasi. Hasil pelatihan yang telah dijalankan menggunakan dataset dengan augmentasi transformasi dan *color jitter* adalah sebagai berikut:

**Gambar 4. Grafik Accuracy Menggunakan Augmentasi Transformasi dan Color Jitter**




Sumber: dokumentasi peneliti, 2024

**Gambar 5. Grafik Loss Menggunakan Augmentasi Transformasi dan Color Jitter**




Hasil iterasi ke-500 untuk data yang menggunakan augmentasi transformasi dan *color jitter* menghasilkan nilai akurasi sebesar 0,9375 dan *loss* sebesar 0,1915 untuk data *train*, serta nilai akurasi sebesar 0,9033 dan *loss* sebesar 0,3264 untuk data *test*. Sedangkan untuk data tanpa augmentasi transformasi dan *color jitter* pada iterasi ke-500 menghasilkan nilai akurasi sebesar 1,0000 dan *loss* sebesar 0,00002 untuk data *train*, serta nilai akurasi sebesar 0,8633 dan *loss* sebesar 1,6586 untuk data *test*. Hasil ini dapat dilihat secara detail sebagai berikut:

**Gambar 6. Grafik Accuracy Tanpa Augmentasi Transformasi dan Color Jitter**



Sumber: dokumentasi peneliti, 2024

**Gambar 7. Grafik Loss Tanpa Augmentasi Transformasi dan Color Jitter**



Dengan menggunakan augmentasi transformasi dan *color jitter*, hasil pelatihan menunjukkan hasil yang lebih baik dibandingkan dengan dataset tanpa proses tersebut. Dimana terdapat kecenderungan *overfitting* yang terlihat pada grafik, model cenderung menghafal data *training* sehingga akurasi pada data *testing* menurun. Meskipun akurasi pada data *training* bisa mencapai 100%, akurasi pada data *testing*

lebih rendah dibandingkan dengan dataset yang menggunakan augmentasi transformasi dan *color jitter*. Ini mengindikasikan bahwa augmentasi transformasi dan *color jitter* memiliki dampak positif terhadap kinerja model dengan meningkatkan *generalisasi*, mengatasi *overfitting*, dan membuatnya lebih tangguh terhadap variasi pada data dunia nyata.

e. *Evaluation*

Langkah berikutnya adalah melakukan evaluasi terhadap data yang belum pernah digunakan dalam dataset *training* maupun *testing* sebelumnya. Evaluasi ini bertujuan untuk menguji kemampuan model terhadap data baru, memberikan gambaran tentang kinerja model dalam situasi dunia nyata. Dalam evaluasi ini, digunakan 15 gambar yang belum pernah dilihat oleh model sebelumnya. Hasil uji coba menunjukkan bahwa model berhasil mencapai akurasi sebesar 100%, yang menandakan kemampuan model dalam mengklasifikasikan data baru dengan baik. Akurasi ini menunjukkan bahwa model tidak hanya menghafal data *training*, tetapi juga mampu mengenali dan mengklasifikasikan pola-pola baru secara baik.

Gambar 8. Sample Gambar Uji Coba



Hasil dari metode *Convolutional Neural Network* dengan Augmentasi Transformasi dan *Color Jitter* menggunakan *TensorFlow* dalam pengklasifikasian kematangan buah *berry* menunjukkan tingkat akurasi yang baik. Setelah dilakukan pelatihan sebanyak 500 *epoch*, model berhasil mencapai akurasi sebesar 93,75% untuk data *train* dan 90,33% untuk data *test*. Terhadap 30 data baru yang berbeda dari data *train* dan data *test*, model berhasil mencapai akurasi sebesar 100%. Penggunaan augmentasi transformasi dan *color jitter* terbukti memiliki pengaruh cukup positif terhadap kinerja model, dengan data *test* menunjukkan tingkat akurasi yang lebih baik serta nilai *loss* yang lebih rendah. Untuk penelitian selanjutnya dapat disarankan untuk memperbanyak dataset gambar yang digunakan sebagai data *train* dan data *test*, memperkaya variasi gambar buah *berry* yang dapat dikenali oleh model agar



meningkatkan akurasi dan generalisasi model dalam mengklasifikasikan kematangan buah berry.

Selain itu, eksperimen dengan variasi teknik augmentasi lainnya selain transformasi dan *color jitter* juga perlu dilakukan untuk melihat dampaknya terhadap kinerja model CNN. Selain itu disarankan juga untuk mencoba melakukan integrasi teknologi lain seperti *transfer learning* atau *ensemble learning* dapat memperkuat kinerja model dalam klasifikasi buah berry. Eksperimen dengan variasi parameter pelatihan seperti jumlah *epoch*, *learning rate*, dan *batch size* juga penting untuk menemukan kombinasi optimal yang meningkatkan performa model. Penelitian lebih lanjut terkait penggunaan teknologi CNN dalam konteks klasifikasi buah berry diharapkan dapat membuka peluang aplikasi dan pengembangan lebih lanjut dalam industri pertanian.

### C. Penutup

Kesimpulan dari penelitian ini menunjukkan bahwa implementasi metode Convolutional Neural Network (CNN) dengan Augmentasi Transformasi dan Color Jitter menggunakan TensorFlow memiliki tingkat keberhasilan yang tinggi dalam mengklasifikasikan tingkat kematangan buah berry berdasarkan gambar. Dengan pelatihan sebanyak 500 epoch, model mampu mencapai akurasi sebesar 93,75% untuk data latih dan 90,33% untuk data uji, serta menunjukkan performa luar biasa pada data baru dengan akurasi mencapai 100%. Hasil ini menunjukkan bahwa penggunaan augmentasi transformasi dan color jitter dapat meningkatkan kemampuan generalisasi model, memperbaiki akurasi, serta mengurangi nilai loss pada data uji. Augmentasi yang digunakan, seperti rotasi, flipping, dan perubahan pada hue, saturasi, brightness, serta contrast, terbukti efektif dalam memperkaya data latih dan memperkuat model dalam menangani variasi visual pada gambar buah. Hal ini menegaskan pentingnya augmentasi data dalam memperbaiki performa model CNN dalam konteks klasifikasi gambar buah. Namun, penelitian ini juga menyadari adanya beberapa batasan yang perlu diperhatikan dalam studi lanjutan. Salah satunya adalah perlunya penambahan dataset gambar yang lebih besar dan lebih beragam agar model dapat lebih generalis dan robust terhadap variasi jenis buah berry. Selain itu, eksplorasi teknik augmentasi lainnya serta penerapan metode pembelajaran seperti transfer learning dan ensemble learning disarankan untuk meningkatkan performa model lebih lanjut. Eksperimen terhadap parameter pelatihan, termasuk jumlah epoch, learning rate, dan batch size, juga penting untuk mencapai hasil yang optimal. Secara keseluruhan, penelitian ini berkontribusi signifikan dalam membuka peluang aplikasi teknologi CNN dalam klasifikasi buah di

industri pertanian, khususnya untuk meningkatkan kualitas dan efisiensi produksi buah berdasarkan tingkat kematangan.

### Referensi

- Akhmad Fadjeri, Arief Setyanto, and Mei Kurniawan “Pengolahan Citra Digital Untuk Menghitung Ekstraksi Ciri Greenbean Kopi Robusta dan Arabika (Studi Kasus: Kopi Temanggung)”, 2020, doi:10.30646/tikomsin.v8i1.462.
- Anandhavalli Muniasamy and Areej Alasiry, “Deep Learning: The Impact on Future eLearning. *International Journal of Emerging Technologies*”, 2020, <https://doi.org/10.3991/ijet.v15i01.11435>
- Dani, “Budidaya Blackberry, Blueberry dan Raspberry Untung hingga 65%”, 2019. <https://berempat.com/bisnis/umkm/9893/budidaya-blackberry-blueberry-dan-raspberry-untung-hingga-65>
- Harshit Kumar, “Data Augmentation Techniques”, 2024, <https://iq.opengenus.org/data-augmentation/>
- Laith Alzubaidi, Jinglan Zhang, Amjad J. Humaidi, Ayad Al-Dujaili, Ye Duan, Omran Al-Shamma, J. Santamaría, Mohammed A. Fadhel, Muthana Al-Amidie and Laith Farhan, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions”, 2021, <https://doi.org/10.1186/s40537-021-00444-8>
- Sumit Saha, “A Comprehensive Guide to Convolutional Neural Networks”, 2018. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- Tran Xuan Truong, Viet-Ha Nhu, Doan Thi Nam Phuong, Le Thanh Nghi, Nguyen Nhu Hung, Pham Viet Hoa, and Dieu Tien Bui, “A New Approach Based on TensorFlow Deep Neural Networks with ADAM Optimizer and GIS for Spatial Prediction of Forest Fire Danger in Tropical Areas”, 2023, <https://doi.org/10.3390/rs15143458>
- Tutut Furi Kusumaningrum, “Implementasi Convolution Neural Network (CNN) untuk Klasifikasi Jamur Konsumsi Di Indonesia Menggunakan Keras”, 2018.
- Zaharchuk, Gong, Wintermark, Rubin, and Langlotz, “Deep Learning in Neuroradiology. *American Journal of Neuroradiology*”, 2018, <https://doi.org/10.3174/ajnr.A5543>