

Penerapan *Deep Learning* Berbasis *Resnet-9* Untuk Klasifikasi Penyakit *Blight* Pada Tanaman Kentang Dan Tomat

Burhan Ahmad¹, Alamsyah²

¹Jurusan Ilmu Komputer, FMIPA, Universitas Negeri Semarang (8 pt)

^{2,3}Jurusan Matematika, FMIPA, Universitas Negeri Semarang

Email: ¹bur3112003@students.unnes.ac.id, ²email_penulis_dua

Abstrak

Penyakit *early blight* dan *late blight* merupakan ancaman serius bagi tanaman kentang dan tomat, yang menyebabkan kerugian signifikan bagi petani. Deteksi dini penyakit ini sangat penting agar tindakan penanggulangan dapat dilakukan secara cepat dan efektif. Teknologi machine learning telah banyak diterapkan untuk membantu identifikasi penyakit blight, namun performa metode yang ada masih belum optimal. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit blight yang lebih akurat dengan optimasi arsitektur *ResNet-9* dan *hyperparameter*. Penelitian ini dimulai dengan pemilihan dataset berdasarkan studi sebelumnya yang mencakup gambar daun tanaman kentang dan tomat yang terinfeksi blight. Dataset tersebut kemudian diproses melalui tahapan *preprocessing*, seperti pemisahan, normalisasi, augmentasi data, dan pengubahan ukuran gambar. Selanjutnya, pengembangan model dilakukan dengan optimasi layer-layer pada arsitektur *ResNet-9* agar mampu mengenali pola visual dari penyakit dengan lebih baik. Kemudian model diimplementasikan menggunakan *hyperparameter* yang dioptimalkan untuk mencapai hasil terbaik. Hasil pengujian menunjukkan bahwa model *ResNet-9* berhasil meningkatkan kinerja prediksi penyakit *blight* pada tanaman kentang dan tomat secara signifikan. Model yang diusulkan mencapai akurasi sebesar 99,32%, presisi keseluruhan sebesar 99%, *recall* keseluruhan sebesar 99,33%, dan skor F1 keseluruhan sebesar 99,33%. Kebaruan penelitian ini terletak pada optimasi model dan *hyperparameter* yang diterapkan, sehingga memberikan kontribusi pada peningkatan performa klasifikasi penyakit blight yang lebih baik dibandingkan pendekatan lain.

Kata Kunci: *blight*, kentang, tomat, *machine learning*, *ResNet-9*, *hyperparameter*

Abstract

Early blight and late blight diseases pose a serious threat to potato and tomato crops, causing significant losses to farmers. Early detection of this disease is very important so that countermeasures can be carried out quickly and effectively. Machine learning technology has been widely applied to help identify blight diseases, but the performance of existing methods is still not optimal. Therefore, this study aims to develop a more accurate blight disease classification model with ResNet-9 architecture optimization and hyperparameters. The study began with the selection of datasets based on previous studies that included images of blight-infected potato and tomato plant leaves. The dataset is then processed through preprocessing stages, such as separation, normalization, data augmentation, and image resizing. Furthermore, the development of the model is carried out by optimizing the layers in the ResNet-9 architecture to be able to better recognize the visual patterns of diseases. Then the model is implemented using optimized hyperparameters to achieve the best results. The test results show that the ResNet-9 model has succeeded in significantly improving the prediction performance of blight disease in potato and tomato plants. The proposed model achieved an accuracy of 99.32%, an overall precision of 99%, an overall recall of 99.33%, and an overall

F1 score of 99.33%. The novelty of this study lies in the optimization of the model and the hyperparameters applied, thus contributing to the improvement of the performance of blight disease classification which is better than other approaches.

Keyword: *early blight, late blight, kentang, tomat, machine learning, penyakit blight, ResNet-9, hyperparameter, preprocessing, augmentasi*

1. PENDAHULUAN

Kentang dan tomat merupakan dua tanaman yang memberikan kontribusi besar sebagai bahan makanan dan pendapatan petani di dunia[1],[2]. Namun, kedua tanaman ini sering mengalami masalah serius akibat penyakit *blight* seperti *early blight* dan *late blight* [3], yang mengakibatkan kerugian besar bagi petani. Oleh karena itu, prediksi terhadap penyakit pada tanaman kentang dan tomat sangat penting untuk membantu petani mengambil tindakan yang cepat dan tepat. Hal tersebut akan mempermudah proses pertanian dan mengurangi kerugian petani. Prediksi penyakit pada tanaman dapat dilakukan dengan menerapkan teknologi-teknologi yang ada pada saat ini.


Artificial Intelligence adalah salah satu teknologi yang dapat digunakan untuk memprediksi penyakit pada tanaman [4]. Umumnya, penerapan *Artificial Intelligence* untuk prediksi penyakit pada tanaman, menggunakan Machine learning[5],[6]. Machine learning terdiri dari berbagai model yang dapat digunakan untuk prediksi penyakit pada tanaman, seperti CNN [7-9], Support Vector Machine (SVM) [10],[11], DNN [12], dan sebagainya.

Secara khusus, dalam prediksi penyakit blight pada tanaman terdapat berbagai model machine learning yang pernah digunakan seperti *Support Vector Machine* (SVM) [13] dimana dalam proses pengolahan citra menggunakan *Graph Cut Segmentation* [14], *Random Forest* [15], dan. Terdapat penerapan model deep learning seperti *DenseNet Xception* [16], VGG-19 [17], *deep learning* dengan 14-layer [18], dan VGG-16 [19].

Untuk menentukan apakah suatu model dapat memprediksi penyakit blight dengan baik dapat dilihat dari tingkat akurasi model yang digunakan. Dari penelitian-penelitian sebelumnya yang mendapat akurasi tertinggi adalah penelitian menggunakan model VGG-16 [19]. Namun, penelitian tersebut belum mendapatkan hasil yang maksimal dalam prediksi penyakit blight pada tanaman kentang dan tomat. Oleh karena itu, pada penelitian ini akan dilakukan pengembangan model *ResNet-9* dengan memodifikasi beberapa layer untuk meningkatkan akurasi dalam prediksi penyakit blight pada tanaman kentang dan tomat melalui citra daun.

2. METODE

Pada penelitian ini, metode yang diusulkan ditunjukkan pada Gambar 1, setiap langkah pada Gambar 1 akan dijelaskan secara rinci pada bahasan selanjutnya.



Gambar 1. Flowchart dari metode yang diusulkan

2.1. Dataset

Dataset citra yang digunakan diperoleh dari jurnal sebelumnya [20] yang diambil dari Kaggle. Lebih lengkap, ditunjukkan pada Tabel 1.

Tabel 1. Dataset

Jenis Tanaman	Kelas	Jumlah Gambar	Total
Potato	Early Blight	1.000	2.152
	Healthy	152	
	Late Blight	1.000	
Tomato	Early Blight	1.000	4.500
	Healthy	1.591	
	Late Blight	1.909	
Total			6.652

2.2. Data Preprocessing

Pada penelitian ini, pemisahan dataset dilakukan dengan perbandingan 60:20:20 untuk pelatihan, validasi, dan pengujian. Lebih lengkap, disajikan pada Tabel 2.

Tabel 2. Hasil pemisahan dataset

Set	Jumlah Gambar
Pelatihan	3.990
Validasi	1.331
Uji	1.331
Total	6.652

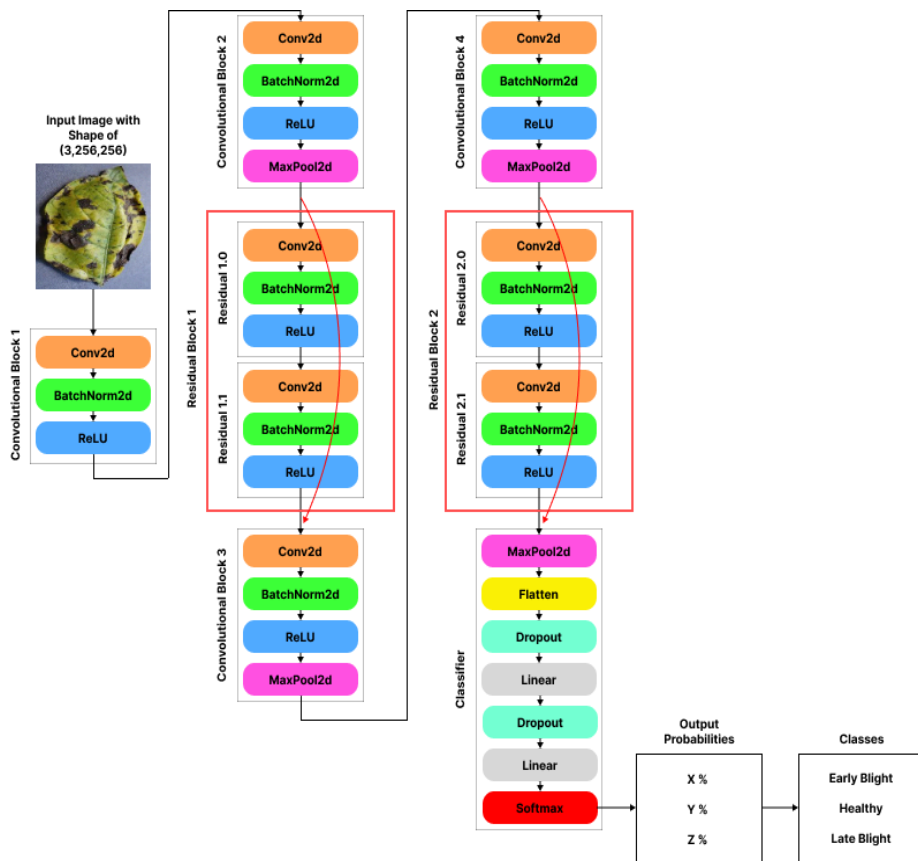
Normalisasi gambar dengan membagi piksel gambar dengan nilai 255, sehingga nilai piksel berubah menjadi rentang 0 hingga 1. Teknik augmentasi yang diterapkan pada gambar-gambar dalam set pelatihan. Teknik augmentasi yang digunakan adalah *center crop*, *gaussian blur*, dan *random rotation*. *Center crop* digunakan untuk memotong gambar di bagian tengah dengan ukuran yang ditentukan [21]. Penelitian ini menggunakan fungsi *center crop* dengan ukuran yang akan dipilih acak dari [180,200,220,240], dimana ukuran asli gambar 256x256. *Gaussian blur* mengurangi kejelasan atau kekasaran detail gambar [22]. Untuk augmentasi gaussian blur, menggunakan nilai sigma dari rentang (1,15,2,2.5). *Random rotation* digunakan untuk merubah rotasi gambar [23]. Sudut yang digunakan dari 50°, 70°, 100°, 130°, dan 150°, yang dipilih secara acak. Hasil augmentasi disajikan pada Tabel 3

Tabel 3. Hasil augmentasi dataset

Himpunan data	Kelas	Jumlah Gambar	Jumlah Gambar Total
Pelatihan	Early blight	3.996	12.009
	Health	4.001	
	Late blight	4.002	
Validasi	Early blight	442	1331
	Health	443	
	Late blight	446	
Tes	-	-	1331

2.3. Klasifikasi Daun Kentang dan Tomat Menggunakan Model Resnet-9

ResNet (*residual networks*) adalah jaringan yang memungkinkan lapisan (*residual blocks*) agar sesuai menggunakan pemetaan residual alih-alih berharap setiap beberapa lapisan ditumpuk secara langsung [24]. *ResNet-9* menggunakan Sembilan layer, dimana pada penelitian ini menggunakan model *ResNet-9* dalam framework PyTorch untuk melatih model pada GPU Kaggle NVIDIA T4 x2. Model ini terdiri dari empat blok konvolusional, dua blok residu yang masing-masing terdiri dari dua lapisan residu, dan satu pengklasifikasi, dengan total sembilan lapisan. *Convolutional Block 1* merupakan lapisan masukan yang menerima data gambar daun tanaman dan meneruskannya ke lapisan tersembunyi untuk pengolahan lebih lanjut. Lapisan tersembunyi terdiri dari *Convolutional Layer 2* hingga *Linear Layer* di *Classifier*. Di lapisan *Classifier*, dilakukan modifikasi dengan menambahkan jumlah *Linear Layer* dan fungsi *Dropout* untuk mengurangi *overfitting*. Keluaran dari model *ResNet-9* ini adalah lapisan *Softmax*, yang menghasilkan probabilitas kelas dengan prediksi tertinggi sebagai hasil akhir. Lebih lengkap, Ilustrasi model *ResNet-9* ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur ResNet-9

Gambar input memiliki ukuran [3, 256, 256] dimana mewakili jumlah kanal warna (merah, hijau, dan biru), lebar, dan tinggi gambar. Pertama-tama, gambar input melalui Blok Konvolusi 1 di mana operasi *Conv2D* diterapkan untuk mengekstraksi fitur seperti warna, tekstur, tepi, dan bentuk dari gambar, kemudian dinormalisasi oleh lapisan normalisasi *batch* sebelum masuk ke lapisan berikutnya [25], normalisasi *batch* memungkinkan gradien memiliki perilaku yang stabil, yang memungkinkan pelatihan jaringan menjadi lebih cepat. Akhirnya, fungsi aktivasi *ReLU*, yang merupakan fungsi aktivasi non-linear, mentransformasikan data secara non-linear untuk dapat dipisahkan secara linear, untuk klasifikasi dalam penelitian ini. Di lapisan tersembunyi, gambar input terus melalui operasi *Conv2D*, normalisasi *batch*, dan *ReLU* dengan tambahan operasi *MaxPooling2D* dengan ukuran *kernel* 4 yang mengurangi pengukuran spasial (tinggi dan lebar) input, sehingga fitur paling penting dapat diekstraksi dari gambar. Dari lapisan saat ini ke lapisan selanjutnya, tinggi dan lebar gambar input berkurang saat melalui blok-blok jaringan. Pada blok residual terakhir lapisan tersembunyi (yaitu, *Residual Block 2.1*), nilai channel tumbuh menjadi 512, nilai tinggi dan lebar berkurang menjadi 4. Operasi *MaxPooling2D* terakhir pada lapisan tersembunyi mengurangi dimensi tinggi dan lebar dari 4 menjadi 1 masing-masing. Lapisan *flatten* merombak bentuk tensor input menjadi satu dimensi

agar fungsi softmax dapat diterapkan. Fungsi *dropout* digunakan untuk mengurangi *overfitting*. Fungsi linier, yang merupakan lapisan terhubung penuh, kemudian mengirimkan data ke lapisan *softmax*. Lapisan *softmax* yang terdapat pada lapisan *output* mengubah skala tensor input menjadi rentang [0,1], menjadikan jumlah semua tensor sama dengan satu, dan mengembalikan probabilitas gambar input termasuk ke dalam salah satu dari tiga kelas. Kelas dengan probabilitas tertinggi akan menjadi kelas yang diprediksi untuk gambar tersebut.

2.4. Pelatihan dan Validasi

Dataset pelatihan hasil proses augmentasi berisi 12.009 gambar dan validasi berisi 1331 gambar akan digunakan untuk proses pelatihan dan validasi model *ResNet-9*. Pelatihan dan validasi model dilakukan dengan menerapkan hyperparameter terbaik yang didapatkan pada pembahasan sebelumnya.

2.5. Pengujian

Dataset uji yang berisi 1331 gambar akan digunakan untuk menguji model *ResNet-9*. Hasilnya akan dapat digunakan untuk evaluasi model.

2.6. Evaluasi Model

Untuk mengevaluasi kinerja model dapat dengan melihat evaluation metrics [27]. Contoh perhitungan evaluation metrics meliputi akurasi, presisi, *recall*, dan skor f1 pada set pengujian terdapat pada persamaan (1), (2), (3), dan (4).

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

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

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

$$\text{F1-Score} = 2 \frac{\text{Presisi} \cdot \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1. Confusion Matrix

Pada penelitian ini, *Confusion matrix* hasil pengujian model *ResNet-9* menunjukkan kelas sebenarnya dan prediksi yang dilakukan model yaitu ditunjukkan pada Gambar 4.



Gambar 4. Confusion matrix dari modifikasi model *ResNet-9*

3.2. Classification Report untuk Model *Resnet-9*

Pada penelitian ini, akurasi pada set pengujian untuk model *ResNet-9* modifikasi mencapai 0,9962 (99,62%). Classification Report untuk modifikasi model *ResNet-9* ditunjukkan pada Tabel 5.

Tabel 5. Classification report for model *ResNet-9* yang dimodifikasi

Class	Precision	Recall	F1-Score
Early Blight	99.00%	100.00%	99.00%
Healthy	100.00%	100.00%	100.00%
Late Blight	100.00%	100.00%	100.00%
Overall	99.67%	100.00%	99.67%

Tabel diatas menyajikan presisi, *recall*, dan skor F1 untuk ketiga kelas. Nilai tertinggi untuk presisi, *recall*, dan skor F1 adalah 100%. Sedangkan, nilai terendah untuk presisi adalah 99%, *recall* terendah adalah 100%, dan skor F1 terendah adalah 99%.

3.3. Perbandingan Modifikasi Model *Resnet-9* pada Penelitian Ini dengan Model Lain pada Penelitian Sebelumnya.

Perbandingan singkat dari pendekatan yang sudah ada untuk deteksi penyakit *blight* bersama dengan pendekatan penelitian ini ditunjukkan pada Tabel 6

Tabel 6. Perbandingan berbagai pendekatan untuk deteksi penyakit blight

Peneliti	Pendekatan	Akurasi Pengujian
Singh & Kaur [5]	Image segmentation, K-means clustering and image classification with SVM model.	95.99%
Iqbal & Talukder [6]	Image processing, segmentation and feature extraction. Image classification with a random forest model.	97.00%
Hong et al. [16]	Image classification with densenet xception deep learning model.	97.10%
Hou et al. [14]	Image segmentation with graph cut algorithm and image classification with SVM model.	97.40%
Tiwari et al. [17]	Feature extraction with VGG-19 pre-trained model for image classification.	97.80%
Khalifa et al. [18]	Image classification with 14-layer deep learning model.	98.00%
Kumar & Vani [19]	Image classification with VGG-16 model.	99.11%
Penelitian Ini	Image classification with ResNet-9 model modified.	99.62%

Modifikasi model *ResNet-9* dari penelitian ini, dibandingkan dengan semua metode lain dalam Tabel 6, memiliki akurasi pengujian yang paling unggul. Hal ini disebabkan pada augmentasi data yang ketat, normalisasi gambar, penyetelan *hyperparameter* yang terbaik sebelum pelatihan dan evaluasi model, dan modifikasi beberapa layer model secara tepat.

4. SIMPULAN

Modifikasi Model *ResNet-9* pada beberapa layer dengan menambahkan *Linear Layer* dan fungsi *Dropout* untuk mengurangi *overfitting* ditambah dengan menguji model menggunakan *hyperparameter* terbaik pada jurnal sebelumnya, berhasil mendapatkan akurasi yang lebih tinggi dari penelitian-penelitian sebelumnya sebesar 99.62% dalam mendeteksi penyakit blight pada citra daun kentang dan tomat.

5. REFERENSI

- [1] S.S , . Hoge, Tuta absoluta (meyrick) (Lepidoptera: Gelechiidae) – biology, ecology, prevention and control measures and means in greenhouse tomato

- crops. A review, *Current Trends in Natural Sciences* 9 (2020) 222–231, <https://doi.org/10.47068/ctns.2020.v9i17.028>.
- [2] Azimuddin, M. D., Q. M. Alam, and M. A. Baset. "Potato for food security in Bangladesh." *International Journal of Sustainable Crop Production* 4.1 (2009): 94-99.
- [3] Rotem, J. (1994). *The genus Alternaria: biology, epidemiology, and pathogenicity*. American Phytopathological Society, [http://refhub.elsevier.com/S2772-3755\(23\)00008-4/sbref0003](http://refhub.elsevier.com/S2772-3755(23)00008-4/sbref0003).
- [4] Thangaraj, R., Anandamurugan, S., Pandiyan, P., & Kaliappan, V. K. (2022). Artificial intelligence in tomato leaf disease detection: a comprehensive review and discussion. *Journal of Plant Diseases and Protection*, 129(3), 469-488.
- [5] A. Singh, H. Kaur, Potato plant leaves disease detection and classification using machine learning methodologies, *IOP Conf. Ser.: Mater. Sci. Eng.* 1022 (Jan. 2021), 012121, <https://doi.org/10.1088/1757-899X/1022/1/012121>.
- [6] M.A. Iqbal, K.H. Talukder, Detection of potato disease using image segmentation and machine learning, in: 2020 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), 2020, pp. 43–47, <https://doi.org/10.1109/WiSPNET48689.2020.9198563>
- [7] Sardogan M, Tuncer A, Ozen Y (2018) Plant leaf disease detection and classification based on CNN with LVQ algorithm. In 2018 3rd International Conference on Computer Science and Engineering (UBMK) (pp. 382–385). IEEE.
- [8] Karthik R, Hariharan M, Anand S, Mathikshara P, Johnson A, Menaka R (2020) Attention embedded residual CNN for dis-ease detection in tomato leaves. *Appl Soft Comput* 86:105933
- [9] Agarwal M, Singh A, Arjaria S, Sinha A, Gupta S (2020) ToLeD: tomato leaf disease detection using convolution neural network. *Procedia Computer Science* 167:293–301
- [10] Das D, Singh M, Mohanty SS, Chakravarty S (2020) Leaf Disease Detection using Support Vector Machine. In 2020 International Conference on Communication and Signal Processing (ICCSP) (pp. 1036–1040). IEEE.
- [11] Mokhtar U, El Bendary N, Hassenian AE, Emary E, Mahmoud MA, Hefny H, Tolba MF (2015c) SVM-based detection of tomato leaves diseases. *intelligent systems*. Springer International Publishing, Berlin, pp 641–652.
- [12] Gadekallu TR, Rajput DS, Reddy MPK, Lakshmana K, Bhattacharya S, Singh S, Alazab M (2020) A novel PCA-whale optimization-based deep neural network model for classification of tomato plant diseases using GPU. *J Real-Time Image Process.* 1–14.
- [13] Patil, P., Yaligar, N., & Meena, S. M. (2017, December). Comparison of performance of classifiers-svm, rf and ann in potato blight disease detection using leaf images. In *2017 IEEE international conference on computational intelligence and computing research (ICIC)* (pp. 1-5). IEEE.
- [14] Chaojun Hou, Jiajun Zhuang, Yu Tang, Yong He, Aimin Miao, Huasheng Huang, Shaoming Luo, Recognition of early blight and late blight diseases on potato leaves based on graph cut segmentation, *J. Agric. Food Res.* 5 (2021), 100154, <https://doi.org/10.1016/j.jafr.2021.100154>. ISSN: 2666-1543.

- [15] Meno, L., Escuredo, O., Abuley, I. K., & Seijo, M. C. (2023). Predicting Daily Aerobiological Risk Level of Potato Late Blight Using C5. 0 and Random Forest Algorithms under Field Conditions. *Sensors*, 23(8), 3818.
- [16] H. Hong, J. Lin, F. Huang, Tomato disease detection and classification by deep learning, in: 2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE), 2020, pp. 25–29, <https://doi.org/10.1109/ICBAIE49996.2020.00012>.
- [17] D. Tiwari, et al., Potato leaf diseases detection using deep learning, in: 2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS) (2020), 2020, pp. 461–466, <https://doi.org/10.1109/ICICCS48265.2020.9121067>.
- [18] Khalifa, N. E., Taha, M., Abou El-Magd, L. & Hassanien, A. E. Artificial intelligence in potato leaf disease classification: a deep learning approach in (Jan. 2021), 63–79. ISBN: 978-3-030-59337-7.
- [19] A. Kumar, M. Vani, in: Image Based Tomato Leaf Disease Detection in 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT), 2019, pp. 1–6, <https://doi.org/10.1109/ICCCNT45670.2019.8944692>.
- [20] Yuan, Y., Fang, S., & Chen, L. (2018). Crop disease image classification based on transfer learning with DCNNs. In *Pattern Recognition and Computer Vision: First Chinese Conference, PRCV 2018, Guangzhou, China, November 23-26, 2018, Proceedings, Part II 1* (pp. 457-468). Springer International Publishing.
- [21] Ellefsen, K. L., Lock, J. T., Settle, B., Karsten, C. A., & Parker, I. (2019). Applications of FLIKA, a Python-based image processing and analysis platform, for studying local events of cellular calcium signaling. *Biochimica Et Biophysica Acta (BBA)-Molecular Cell Research*, 1866(7), 1171-1179.
- [22] Zhang, Yulun, Kai Zhang, Zheng Chen, Yawei Li, Radu Timofte, Junpei Zhang, Kexin Zhang et al. "NTIRE 2023 challenge on image super-resolution (x4): Methods and results." In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 1864-1883. 2023.
- [23] Abd Elaziz, M., Dahou, A., Abualigah, L., Yu, L., Alshinwan, M., Khasawneh, A. M., & Lu, S. (2021). Advanced metaheuristic optimization techniques in applications of deep neural networks: a review. *Neural Computing and Applications*, 1-21.
- [24] Santurkar, S., Tsipras, D., Ilyas, A., & Madry, A. (2018). How does batch normalization help optimization?. *Advances in neural information processing systems*, 31, [http://refhub.elsevier.com/S2772-3755\(23\)00008-4/sbref0018](http://refhub.elsevier.com/S2772-3755(23)00008-4/sbref0018).
- [25] Smith, L. N. A disciplined approach to neural network hyper-parameters: Part 1–learning rate, batch size, momentum, and weight decay. arXiv preprint arXiv: 1803.09820 (2018). doi: <https://doi.org/10.48550/arXiv.1803.09820>.
- [26] Murtaza, G., Shuib, L., Abdul Wahab, A. W., Mujtaba, G., Mujtaba, G., Nweke, H. F., ... & Azmi, N. A. (2020). Deep learning-based breast cancer classification through medical imaging modalities: state of the art and research challenges. *Artificial Intelligence Review*, 53, 1655-1720.