



SNESTIK

Seminar Nasional Teknik Elektro, Sistem Informasi,
dan Teknik Informatika

<https://ejurnal.itats.ac.id/snestik> dan <https://sneстиk.itats.ac.id>



Informasi Pelaksanaan :

SNESTIK IV - Surabaya, 27 April 2024

Ruang Seminar Gedung A, Kampus Institut Teknologi Adhi Tama Surabaya

Informasi Artikel:

DOI : 10.31284/p.snestik.2024.5845

Prosiding ISSN 2775-5126

Fakultas Teknik Elektro dan Teknologi Informasi-Institut Teknologi Adhi Tama Surabaya
Gedung A-ITATS, Jl. Arief Rachman Hakim 100 Surabaya 60117 Telp. (031) 5945043

Email : [sneстыk@itats.ac.id](mailto:sneстиk@itats.ac.id)

Teknik Pembesaran Citra Progresif untuk Klasifikasi Tipe Penyakit Daun Padi pada Jaringan Syaraf Tiruan VGG16

Bayu Adhi Nugroho

UIN Sunan Ampel Surabaya

email: bayu.lecture@gmail.com

ABSTRACT

Rice is a prominent staple food in Indonesia. Its production volume is very dependent on the results of crop harvesting. Hence, a method to support the harvest quantity is crucial. Rice leaf diseases are a known factor that significantly reduces the harvest quantity. Artificial intelligence technology to classify rice leaf diseases is helpful for humans since this type of technology is non-exhaustive and can quickly classify massive amounts of data. Traditional classification methods such as SVM or Naive Bayes may be helpful. However, these methods require complex pre-processing for the data before the data can be fed into these methods. Neural network-based methods (e.g. Deep Learning) have the known advantage of easily being fed with image data. This research proposes progressive image resizing within VGG16 neural network architecture. The research problem is that the research hypotheses that progressive image resizing would improve the accuracy of rice leaf disease classification. The research utilizes the VGG16 network with a progressive image resizing algorithm. The final result from the experiments is auspicious, with 96,62 % accuracy.

Keywords: rice, leaf, diseases, classification, CNN

ABSTRAK

Tanaman padi merupakan bahan pangan utama di Indonesia. Produksi tanaman padi sangat bergantung pada hasil panen. Maka, sebuah upaya untuk mendukung kuantitas jumlah panen sangat penting. Penyakit – penyakit daun padi telah diketahui dapat menurunkan kuantitas produksi panen. Teknologi kecerdasan buatan untuk melakukan klasifikasi penyakit – penyakit daun padi sangat membantu manusia karena teknologi semacam ini tidak mengenal lelah dan dapat melakukan klasifikasi data dalam jumlah besar dengan cepat. Metode klasifikasi tradisional seperti SVM dan Naive Bayes dapat digunakan, tetapi metode-metode semacam ini memerlukan *data pre-processing* yang kompleks sebelum dapat digunakan dalam metode tersebut. Metode berbasis Jaringan Syaraf Tiruan (misal: Deep Learning) memiliki keunggulan lebih mudah digunakan dengan data berupa citra. Riset ini menggunakan teknik pembesaran citra progresif dengan arsitektur VGG16. Permasalahan yang dihadapi dalam riset ini adalah adanya hipotesis awal bahwa teknik pembesaran citra progresif akan

meningkatkan akurasi klasifikasi daun padi. Dalam riset ini digunakan arsitektur VGG16 dengan algoritma pembesarn citra progresif. Hasil akhir dari eksperimen yang dilakukan sangat signifikan dengan tingkat akurasi sebesar 96,62 %.

Kata kunci: padi, daun, penyakit, klasifikasi, CNN

PENDAHULUAN

Tanaman padi merupakan sumber komoditas pangan utama di Indonesia [1]. Harga beras yang terus meningkat [2] menunjukkan adanya permintaan yang tinggi akan komoditas beras, tetapi tidak diiringi dengan daya dukung yang optimal oleh hasil produksi dari tanaman padi. Peningkatan produksi beras terkait sangat erat dengan penanganan penyakit pada daun padi. Penentuan penyakit pada tanaman padi dapat dilakukan dengan melakukan pemeriksaan pada wilayah daun [3,4]. Deteksi penyakit daun padi dengan cara manual sudah terbukti kurang handal dan mahal [5]. Pendekatan dengan teknik komputasi untuk melakukan klasifikasi daun padi yang memiliki penyakit yang telah dilakukan, antara lain dengan metode: *support vector machine* (SVM) [6,7], jaringan syaraf tiruan [8]. Namun, penggunaan teknik manipulasi ukuran citra secara progresif [9] untuk meningkatkan klasifikasi penyakit pada daun dari tanaman padi masih belum umum ditemukan pada studi pustaka penelitian – penelitian terbaru.

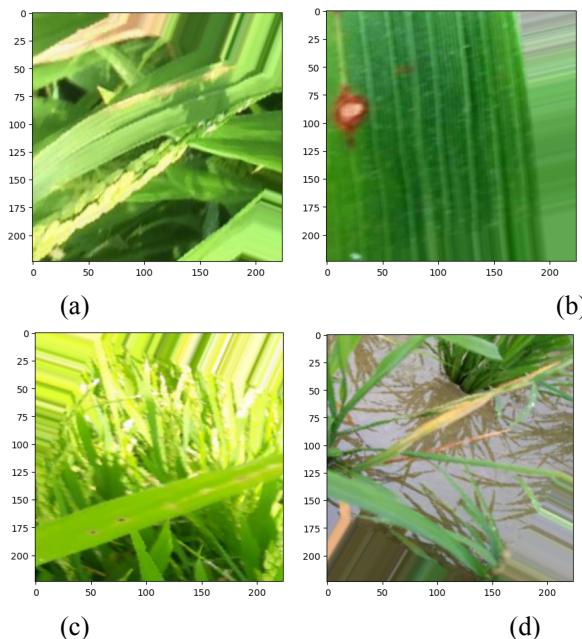
Convolutional Neural Network (CNN) merupakan salah satu teknik berbasis jaringan syaraf tiruan yang umum digunakan untuk melakukan pemecahan masalah dari subyek data berupa citra / gambar. Metode lain yang dapat digunakan adalah *support vector machine* (SVM) [6,7], hanya saja SVM memerlukan proses pemilihan fitur dari citra. Kemampuan CNN cukup handal untuk melakukan tugas tugas terkait tipe data citra / gambar, semisal: deteksi objek pada citra ataupun klasifikasi jenis citra. Namun, salah satu tantangan terbesar penggunaan CNN adalah pemilihan model arsitektur yang digunakan. Hal tersebut terkait dengan sumber daya komputasi yang diperlukan oleh CNN cukup besar untuk memperoleh model CNN yang akurat. Sehingga sebuah permasalahan yang hampir pasti muncul adalah: “Bagaimana memperoleh model CNN yang memerlukan sumber daya komputasi ringan, tetapi memiliki tingkat akurasi yang tinggi ?”.

VGG16 merupakan arsitektur CNN yang menduduki peringkat kedua kompetisi klasifikasi 1000 (seribu) kelas citra / gambar ILSVRC (*ImageNet Large Scale Visual Recognition Competition*) pada tahun 2014 [10]. VGG16 merupakan arsitektur yang digunakan untuk menguji kebenaran hipotesis dalam penelitian ini, yaitu: “**perbesaran citra gambar secara progresif akan meningkatkan hasil klasifikasi penyakit daun padi**”. Tujuan dari penelitian ini adalah membuktikan hipotesis “**perbesaran citra gambar secara progresif akan meningkatkan hasil klasifikasi penyakit daun padi**”, sehingga diperoleh manfaat analisa akan kebenaran hipotesis “**perbesaran citra gambar secara progresif akan meningkatkan hasil klasifikasi penyakit daun padi**”. Arsitektur CNN lain yang memiliki kinerja cukup baik adalah ResNet [11] dan Efficient Net [12].

Perbesaran citra gambar secara progresif untuk meningkatkan hasil klasifikasi telah dilakukan sebelumnya untuk penyakit *lyme* [13]. Penyakit *lyme* merupakan penyakit yang disebabkan kutu dan menyerang manusia. Dalam banyak hal, sumber data citra / gambar yang ditujukan untuk melakukan deteksi penyakit *lyme* pada subyek manusia akan memiliki pola yang berbeda dengan tipe citra / gambar untuk melakukan klasifikasi penyakit pada daun (utamanya pada daun padi). Dalam studi ini akan ditelaah kemampuan teknik pembesaran citra gambar secara progresif yang digunakan pada CNN untuk meningkatkan klasifikasi penyakit daun pada tanaman padi. Teknik pembesaran citra gambar secara progresif pada proses pelatihan CNN dimulai dengan gambar dengan resolusi rendah, kemudian secara bertahap meningkatkan resolusi citra gambar yang digunakan [9]. Model CNN dengan resolusi tinggi diinisialisasi dengan bobot awal dari bobot CNN sebelumnya yang telah dilatih dengan resolusi lebih rendah [9]. Proses ini dilakukan secara berulang, hingga diperoleh hasil akurasi yang sesuai harapan dengan terus melakukan uji-coba *fine-tune* parameter pelatihan.

METODE

Dataset yang digunakan dalam penelitian ini adalah sebuah *dataset* publik dengan citra yang telah terlabel [14]. *Dataset* [14] memiliki 4 (empat) kelas penyakit daun padi, yaitu: *Bacterial Blight*, *Blast*, *Brown Spot* dan *Tungro*. Contoh citra / gambar penyakit pada daun padi yang terdapat dalam dataset adalah seperti pada Gambar 1.



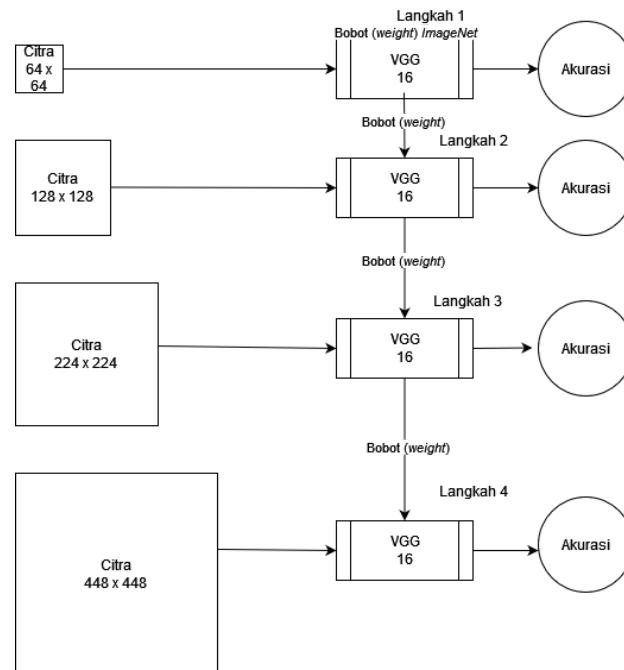
Gambar 1. a) *Bacterial Blight* (b) *Blast* (c) *Brownspot* (d) *Tungro* [14]

Dataset [14] tersebut berisikan total 5932 citra / gambar dari 4 (empat) macam jenis penyakit daun padi. Proses pelatihan dan evaluasi hasil klasifikasi mengikuti proporsi 70:20:10 dengan menggunakan mekanisme pembagian acak untuk *train*-validasi-tes sebagaimana terdapat dalam Tabel 1.

Tabel 1. Proporsi Pembagian Data

Kelas Penyakit	Train	Validasi	Test	Total
<i>Bacterialblight</i>	1110	309	165	1584
<i>Blast</i>	996	290	154	1440
<i>Brownspot</i>	1107	343	150	1600
<i>Tungro</i>	940	244	124	1308

Algoritma yang digunakan dalam penelitian ini adalah berbasis penelitian sebelumnya [9]. Adaptasi yang digunakan dalam penelitian ini terdapat pada Gambar 2. Proses pelatihan arsitektur jaringan syaraf VGG16 dilakukan dengan inisialisasi bobot “ImageNet”, hal ini merupakan proses *transfer-learning* di mana VGG16 akan memiliki pengetahuan dasar tentang pola – pola dalam dataset “ImageNet” [15] yang telah dilatihkan. Hipotesa yang hendak diuji dalam penelitian ini adalah “**perbesaran citra gambar secara progresif akan meningkatkan hasil klasifikasi penyakit daun padi**”, sehingga inisialisasi bobot bukan merupakan variabel yang berpengaruh terhadap hipotesis yang hendak diuji. Pada lapisan terbawah VGG16 yang merupakan lapisan untuk melakukan prediksi, dalam penelitian ini dirubah dari semula adalah 1000 (seribu) *node softmax* menjadi 4 (empat) *node softmax*. Nilai *node* tersebut mengikuti jumlah kelas *dataset* dari “ImageNet” ke jumlah kelas *dataset* penyakit daun padi. Digunakan optimizer Ranger [16] dalam pelatihan dengan menggunakan *learning rate* 0,0001. Proses pelatihan VGG16 dilakukan 4 (empat) langkah dengan 4 (empat) ukuran *input* citra / gambar yang membesar dalam setiap langkah yang dilalui.



Gambar 2 Alur Proses Pembesaran Citra pada VGG16

Arsitektur VGG16 yang telah dirubah lapisan terakhir menjadi 4 (empat) node softmax seperti dalam Tabel 2.

Tabel 2. VGG16 dengan Empat Node Softmax

Lapisan		Feature Map	Ukuran	Ukuran Kernel	Stride	Fungsi Aktivasi
<i>Input</i>	Citra	1	224x224x3			
1	2 x Convolution	64	224x224x64	3x3	1	relu
2	Max Pool	64	112x112x64	3x3	2	relu
3	2 x Convolution	128	112x112x128	3x3	1	relu
4	Max Pool	128	56x56x128	3x3	2	relu
5	2 x Convolution	256	56x56x256	3x3	1	relu
6	Max Pool	256	28x28x256	3x3	2	relu
7	3 x Convolution	512	28x28x512	3x3	1	relu
8	Max Pool	512	14x14x512	3x3	2	relu
10	3 x Convolution	512	14x14x512	3x3	1	relu
11	Max Pool	512	7x7x512	3x3	2	relu
12	Fully Connected		25088			relu
13	Fully Connected		4096			relu
14	Fully Connected		4096			relu

15	Fully Output Connected <i>t</i>	4	softmax
----	--	---	---------

Adapun detail dari 4 (empat) langkah pelatihan sebagaimana terdapat pada Gambar 2 adalah sebagai berikut. Langkah pertama dilakukan dengan ukuran citra 64 x 64, dan VGG16 diinisialisasi dengan bobot dari “ImageNet”. Langkah kedua dilakukan dengan ukuran citra 128 x 128 , dan VGG16 diinisialisasi dengan bobot dari *epoch* terakhir langkah pertama. Langkah ketiga dilakukan dengan ukuran citra 224 x 224 , dan VGG16 diinisialisasi dengan bobot dari *epoch* terakhir langkah kedua. Langkah keempat dilakukan dengan ukuran citra 448 x 448 , dan VGG16 diinisialisasi dengan bobot dari *epoch* terakhir langkah ketiga. Setiap langkah dilakukan dalam 5 (lima) *epoch*. Ukuran dari *batch* yang digunakan adalah 8 (delapan) untuk langkah pertama, dan 4 (empat) untuk langkah yang lain. *Setting* ukuran *batch* ditetapkan berdasarkan asumsi untuk melakukan minimalisasi beban dari RAM pada GPU yang digunakan. Proses pelatihan menggunakan satu buah GPU 1080-TI yang memiliki 11 GB RAM, berjalan pada sistem operasi Ubuntu dengan 32 GB RAM dan CPU i5 7600K Kabylake.

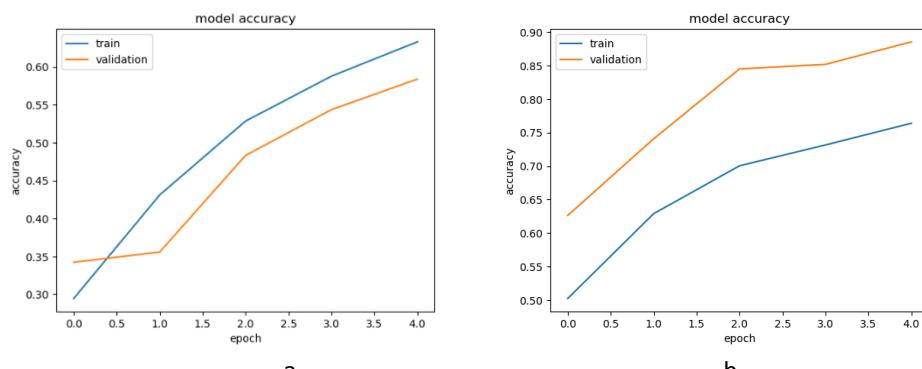
HASIL DAN PEMBAHASAN

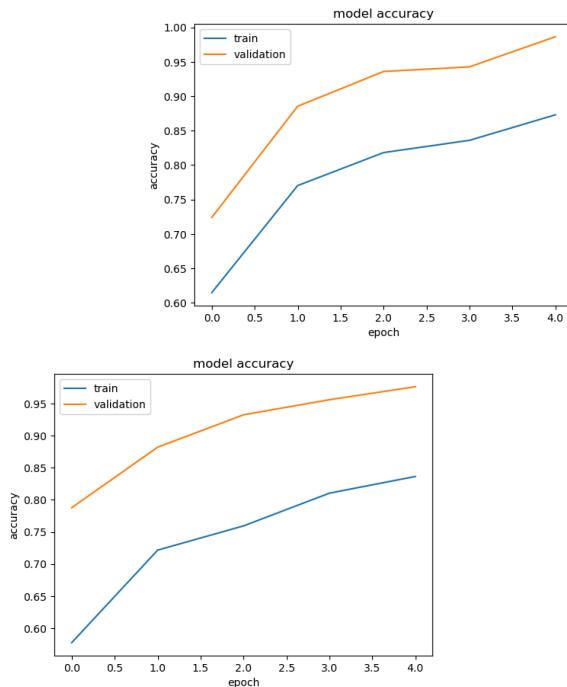
Hipotesis bahwa perbesaran citra secara progresif akan meningkatkan hasil klasifikasi dibuktikan dengan data hasil eksperimen sebagaimana terdapat pada Tabel 3.

Tabel 3 Hasil Akurasi Tes

Langkah	Ukuran Citra (pixel)	Akurasi Tes
1	64 x 64	73,69%
2	128 x 128	90,38%
3	224 x 224	96,62%
4	448 x 448	96,62%

Hasil eksperimen pada Tabel 3 membuktikan bahwa pada langkah pertama hingga ketiga terjadi peningkatan akurasi hasil tes. Pada langkah keempat, akurasi hasil tes mengalami saturasi. Proses saturasi terjadi karena arsitektur jaringan syaraf tidak dapat mengenali fitur – fitur diskriminatif yang dapat meningkatkan hasil klasifikasi, meskipun ukuran citra telah diperbesar. Adapun plot akurasi pada proses pelatihan sebagaimana terdapat pada Gambar 3.



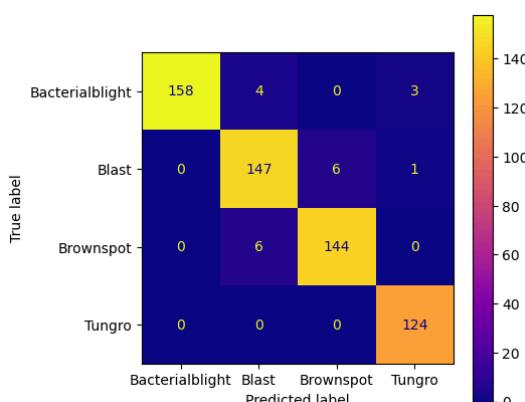


c.

d.

Gambar 3. a) Langkah 1 (b) Langkah 2 (c) Langkah 3 (d) Langkah 4

Pada Gambar 3 menampilkan plot akurasi yang diperoleh pada proses pelatihan dari *split train* dan *val*. Akurasi yang terus meningkat pada peningkatan langkah membuktikan bahwa hipotesa awal bahwa pembesaran ukuran citra secara progresif mampu meningkatkan akurasi secara signifikan. Adapun *confusion matrix* dari akurasi setiap kelas adalah pada Gambar 4, maka Tabel 4 menunjukkan akurasi akhir dari setiap kelas.



Gambar 4 *Confusion Matrix*

Tabel 4 Hasil Akurasi Tes – Kelas

Kelas	Akurasi	Persen
<i>Bacterial Blight</i>	0,957	95,75%
<i>Blast</i>	0,954	95,45%

Brown Spot	0,960	96,00%
Tungro	1	100%
Rerata	0,968	96,80%

KESIMPULAN

Dalam penelitian ini telah dibuktikan efektivitas teknik pembesaran citra progresif untuk klasifikasi penyakit daun padi pada jaringan syaraf tiruan dengan arsitektur VGG16. Hasil yang diperoleh menunjukkan peningkatan akurasi yang signifikan.

DAFTAR PUSTAKA

- [1] M. I. Vadilaksono, Y. Syaukat, and W. Widystutik, “Harmonization of Rice Production Policy and Rice Trade Policy in Indonesia,” *J. Manaj. Dan Agribisnis*, Mar. 2023, doi: 10.17358/jma.20.1.154.
- [2] Noviyanto Rahmadi, “Harga Beras Terus Melonjak Naik di 268 Kabupaten/Kota.” [Online]. Available: <https://ppid.samarindakota.go.id/berita/kabar-pemerintahan/harga-beras-terus-melonjak-naik-di-268-kabupatenkota>
- [3] C. H. Bock, K.-S. Chiang, and E. M. Del Ponte, “Plant disease severity estimated visually: a century of research, best practices, and opportunities for improving methods and practices to maximize accuracy,” *Trop. Plant Pathol.*, vol. 47, no. 1, pp. 25–42, Feb. 2022, doi: 10.1007/s40858-021-00439-z.
- [4] Z. LIU, J. HUANG, and R. TAO, “Characterizing and Estimating Fungal Disease Severity of Rice Brown Spot with Hyperspectral Reflectance Data,” *Rice Sci.*, vol. 15, no. 3, pp. 232–242, 2008, doi: [https://doi.org/10.1016/S1672-6308\(08\)60047-5](https://doi.org/10.1016/S1672-6308(08)60047-5).
- [5] B. S. Bari *et al.*, “A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework,” *PeerJ Comput. Sci.*, vol. 7, p. e432, Apr. 2021, doi: 10.7717/peerj-cs.432.
- [6] P. K. Sethy, N. K. Barpanda, A. K. Rath, and S. K. Behera, “Deep feature based rice leaf disease identification using support vector machine,” *Comput. Electron. Agric.*, vol. 175, p. 105527, 2020, doi: <https://doi.org/10.1016/j.compag.2020.105527>.
- [7] Q. Yao, Z. Guan, Y. Zhou, J. Tang, Y. Hu, and B. Yang, “Application of Support Vector Machine for Detecting Rice Diseases Using Shape and Color Texture Features,” in *2009 International Conference on Engineering Computation*, 2009, pp. 79–83. doi: 10.1109/ICEC.2009.73.
- [8] W. Liang, H. Zhang, G. Zhang, and H. Cao, “Rice Blast Disease Recognition Using a Deep Convolutional Neural Network,” *Sci. Rep.*, vol. 9, no. 1, p. 2869, Feb. 2019, doi: 10.1038/s41598-019-38966-0.
- [9] M. Gogoi and S. A. Begum, “Progressive 3-Layered Block Architecture for Image Classification,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 3, 2022, doi: 10.14569/IJACSA.2022.0130360.
- [10] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” in *International Conference on Learning Representations*, 2015.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [12] M. Tan and Q. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” in *Proceedings of the 36th International Conference on Machine Learning*, K. Chaudhuri

- and R. Salakhutdinov, Eds., in Proceedings of Machine Learning Research, vol. 97. PMLR, Jun. 2019, pp. 6105–6114. [Online]. Available: <https://proceedings.mlr.press/v97/tan19a.html>
- [13] D. Jerrish *et al.*, “Deep learning approaches for lyme disease detection: leveraging progressive resizing and self-supervised learning models,” *Multimed. Tools Appl.*, vol. 83, pp. 1–38, Aug. 2023, doi: 10.1007/s11042-023-16306-9.
- [14] P. K. Sethy, “Rice Leaf Disease Image Samples.” Mendeley, 2020. doi: 10.17632/FWCJ7STB8R.1.
- [15] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, “ImageNet: A Large-Scale Hierarchical Image Database,” in *CVPR09*, 2009.
- [16] L. Wright, “Ranger-Deep-Learning-Optimizer.” Github, 2019. [Online]. Available: <https://github.com/lessw2020/Ranger-Deep-Learning-Optimizer>