

APPLICATION OF CLASS WEIGHT ON RESNET-50 MODEL FOR RICE PLANT DISEASE IMAGE CLASSIFICATION

PENERAPAN *CLASS WEIGHT* PADA MODEL RESNET-50 UNTUK KLASIFIKASI CITRA PENYAKIT TANAMAN PADI

Rahma Alya Zahrani¹, Mochamad Tito Julianto^{2‡}, and Elis Khatizah^{3‡}

^{1,2,3}Mathematics Study Program, IPB University, Indonesia

[‡]corresponding author: alyazahrani@apps.ipb.ac.id

Copyright © 2026 Rahma Alya Zahrani, Mochamad Tito Julianto, and Elis Khatizah. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

Rice plant diseases such as bacterial blight, blast, brown spot, and tungro pose a serious threat to Indonesia's food security. This study develops an image classification model based on ResNet-50 using transfer learning and fine-tuning approaches to detect these four diseases. The main challenge addressed in this study is class imbalance in the dataset, which is handled by applying class weight to the loss function during training. Four experimental scenarios were designed by comparing two optimizers, namely Adam and SGD-M, each tested with and without class weight. The model was evaluated using accuracy, precision, recall, and F1-score metrics. The results show that the best scenario was Adam with class weight, achieving an accuracy of 98,99% and a macro F1-score of 99,01%, compared to Adam without class weight at 98,85% and SGD-M with class weight at 98,60%. In addition, the tungro class achieved a score of 1.00 across evaluation metrics in both scenarios with and without class weight, indicating that tungro has more distinctive visual characteristics compared to the other classes.

Keywords: Class Weight, Image Classification, ResNet-50, Rice Plant Disease, Transfer Learning.

Abstrak

Penyakit tanaman padi seperti bacterial blight, blast, brown spot, dan tungro menjadi ancaman nyata bagi ketahanan pangan Indonesia. Penelitian ini membangun model klasifikasi citra berbasis ResNet-50 dengan pendekatan *transfer learning* dan *fine-tuning* untuk mendeteksi keempat penyakit tersebut. Tantangan utama yang dihadapi adalah ketidakseimbangan distribusi kelas pada dataset, yang diatasi dengan menerapkan *class weight* pada fungsi *loss* selama pelatihan. Empat skenario eksperimen dirancang dengan membandingkan dua *optimizer*, yaitu Adam dan SGD-M, masing-masing dengan dan tanpa *class weight*. Model dievaluasi dengan metrik *accuracy*, *precision*, *recall*, dan F1-score. Hasil menunjukkan bahwa skenario terbaik adalah Adam dengan *class weight* yang menghasilkan *accuracy* 98,99% dan *macro F1-score* 99,01%, dibandingkan Adam tanpa *class weight* sebesar 98,85% dan SGD-M dengan *class weight* sebesar 98,60%. Selain itu, kelas tungro memperoleh nilai 1.00 pada metrik evaluasi untuk skenario dengan penggunaan *class weight* maupun tidak, yang menunjukkan ciri visual tungro berbeda dari kelas lainnya.

Kata Kunci: *Class Weight*, Klasifikasi Citra, Penyakit Tanaman Padi, ResNet-50, *Transfer Learning*.

1. Pendahuluan

Padi (*Oryza sativa* L.) adalah tanaman pangan yang perannya dalam kehidupan manusia hampir tidak tergantikan, terutama di kawasan Asia (Azizi dan Lau 2022). Di Indonesia, posisi padi bahkan lebih dari sekadar komoditas pangan melainkan sebagai identitas budaya, sumber penghidupan jutaan petani, dan pilar utama ketahanan pangan nasional.


Berdasarkan data pada Badan Pusat Statistik (2025) menyatakan produksi padi sebesar 53,14 juta ton Gabah Kering Giling (GKG) yang mengalami penurunan sebesar 1,55% dari tahun 2023. Luas panen padi pada tahun 2024 mencapai 10,05 juta hektare juga mengalami penurunan sebesar 1,64% dari tahun sebelumnya. Salah satu faktor yang menurunkan angka produksi tersebut adalah serangan penyakit tanaman.

Penyakit yang umum dijumpai khususnya di Asia Tenggara adalah bacterial blight (hawar daun bakteri), blast (blas), brown spot (bercak cokelat), dan tungro (Azizi dan Lau 2022). Menghadapi ancaman tersebut, metode deteksi penyakit yang umum diterapkan di lapangan bertumpu pada pengamatan visual secara manual oleh petani atau petugas penyuluh pertanian. Di era perkembangan *Artificial Intelligence* (AI), khususnya *deep learning* telah membuka peluang nyata untuk mengatasi tantangan ini. ResNet-50 merupakan salah satu arsitektur yang banyak digunakan untuk tugas klasifikasi citra.

ResNet-50 dipilih karena memiliki mekanisme *skip connection* yang

memungkinkan model memanfaatkan ulang fitur-fitur yang telah dipelajari dari lapisan-lapisan sebelumnya, mengatasi masalah *vanishing gradient*, dan memungkinkan pelatihan jaringan yang lebih dalam dengan akurasi yang lebih baik (He *et al.* 2016). Pendekatan *transfer learning* yang dikombinasikan dengan *fine-tuning* semakin memperkuat model dalam skenario data berlabel terbatas (Ning *et al.* 2023). Namun, terdapat tantangan mendasar, yaitu permasalahan ketidakseimbangan distribusi kelas (*class imbalance*) pada dataset. Ketidakseimbangan kelas menyebabkan fungsi *loss* selama proses optimasi didominasi oleh kontribusi kelas mayoritas. Salah satu pendekatan untuk menangani ketidakseimbangan kelas adalah *class weighting* (pembobotan kelas), yaitu memodifikasi fungsi *loss* dengan memberikan bobot yang lebih besar pada kelas minoritas selama proses pelatihan.

Beberapa penelitian terdahulu telah mengkaji klasifikasi penyakit tanaman padi menggunakan *deep learning*. Hastari *et al.* (2024) mengusulkan model ResNet-50 V2 dengan menggunakan berbagai



optimizer untuk diagnosis penyakit pada dan mencapai akurasi 99,92%. Bahtiar *et al.* (2025) menggunakan *class weighting* untuk menangani ketidakseimbangan data dengan model ResNet-50 dan mencapai akurasi 89%.


Berdasarkan tinjauan tersebut, kajian ini dilakukan dengan tujuan membangun model ResNet-50 untuk melakukan klasifikasi citra pada penyakit tanaman padi, menganalisis penerapan *class weight* pada fungsi *loss* untuk kinerja model ResNet-50 dalam klasifikasi citra penyakit tanaman padi berdasarkan metrik evaluasi, membandingkan kinerja model ResNet-50 dengan *optimizer* Adam dan SGD-M dalam klasifikasi citra penyakit tanaman padi.

2. Metodologi

2.1 Bahan dan Data

Dataset yang digunakan dalam penelitian ini adalah Rice Leaf Disease dataset yang bersumber dari platform Kaggle. Dataset ini merupakan koleksi citra penyakit daun tanaman padi yang diperoleh dari Mendeley Data dan telah digunakan secara luas. Dataset terdiri dari 5.932 citra yang

terbagi ke dalam 4 kelas penyakit, yaitu bacterial blight berjumlah 1.584, blast berjumlah 1.440, brown spot berjumlah 1.600, dan tungro berjumlah 1.308. Contoh gambar dalam dataset dapat dilihat pada Gambar 1.



Gambar 1: Sampel gambar setiap kelas, yaitu (a) bacterial blight, (b) blast, (c) brown spot, dan (d) tungro.

Bacterial blight merupakan penyakit yang disebabkan oleh bakteri yang menyebabkan daun berwarna kuning pucat hingga abu-abu keputihan yang dimulai dari tepi daun, kemudian meluas ke seluruh permukaan daun. Blast merupakan penyakit jamur pada daun yang menyebabkan daun bercak berbentuk belah ketupat dengan bagian tengah berwarna abu-abu atau putih dan tepi berwarna coklat hingga oranye kemerahan. Brown spot merupakan penyakit jamur yang menyebabkan padi mengalami bercak bulat hingga oval berwarna coklat tua dengan tepi berwarna kuning dan menyebar di seluruh permukaan daun (Hastari *et al.* 2024). Tungro merupakan penyakit virus yang menyebabkan padi mengalami perubahan warna daun dari kuning hingga oranye kemerahan yang dimulai dari ujung daun (Hastari *et al.* 2024).

2.2 Metode Penelitian

Penelitian ini dilakukan menggunakan perangkat lunak Python dengan tahapan penelitian sebagai berikut:

- 1) Pra-pemrosesan data
 - a. *Resize* data dengan gambar diubah ke dimensi 224 x 224 piksel menyesuaikan dengan input standar arsitektur ResNet-50.
 - b. Nilai piksel dinormalisasikan berbasis rata-rata dan standar deviasi dataset ImageNet, yaitu $\mu = [0,485; 0,256; 0,406]$ dan $\sigma = [0,229; 0,224; 0,225]$ untuk masing-masing kanal R, G, dan B.
- 2) Pembagian data

Dataset dibagi menjadi dua subset yaitu data latih dan data uji dengan proporsi 80:20. Berdasarkan total 5.932 gambar, diperoleh 4.745 citra gambar untuk data latih dan 1.187 gambar untuk data uji. Tahap kedua, dari 4.745 citra data latih tersebut diambil 20% sebagai data validasi, sehingga diperoleh 3.796 citra untuk data latih dan 949 citra untuk data validasi. Stratifikasi diterapkan pada setiap tahap pembagian untuk memastikan proporsi tiap kelas tetap terjaga di semua subset.

3) Augmentasi data

Augmentasi data hanya dilakukan pada data latih, sedangkan data validasi dan uji tidak. Pemisahan ini dilakukan untuk memastikan evaluasi dilakukan pada distribusi data yang sesungguhnya sehingga hasil evaluasi mencerminkan kemampuan generalisasi model yang sebenarnya (Shorten dan Khoshgoftaar 2019). Teknik augmentasi yang diterapkan meliputi rotasi, translasi, *zoom*, *flip*, *brightness*, *contrast*, *saturation*, *hue*, dan *noise*.

4) Perancangan model ResNet-50

Dilakukan perancangan model ResNet-50 dengan teknik *transfer learning*. Teknik ini bertujuan untuk mengurangi kebutuhan *training* data dan waktu pelatihan pada domain target untuk melakukan tugas klasifikasi, karena model tidak perlu belajar dari awal melainkan memanfaatkan representasi fitur yang telah terbentuk dari domain sumber (Tan *et al.* 2018). Diterapkan *fine-tuning* pada model, yaitu sebagian atau seluruh bobot model *pre-trained* diperbarui (*trainable*) selama pelatihan pada domain target sehingga representasi fitur yang dihasilkan dapat beradaptasi lebih baik terhadap karakteristik visual dataset target (Zhuang *et al.* 2021). ResNet-50 terdiri dari 5 *stage* konvolusi dengan pada penelitian ini, *stage* konvolusi 1 hingga 4 di *freeze* dan *stage* konvolusi 5 di biarkan *trainable*. Hal ini dilakukan agar *layer* awal mempelajari fitur umum seperti tepi dan tekstur, sedangkan *layer* akhir mempelajari fitur yang lebih abstrak dan spesifik terhadap domain. Dengan melatih *stage* 5, model dapat mengadaptasikan representasi fitur tingkat tinggi untuk mengenali pola visual spesifik pada penyakit tanaman padi. ResNet-50 sendiri merupakan arsitektur CNN dengan 50 *layer* berbobot yang mengorganisir seluruh lapisannya ke dalam 5 *stage* konvolusi. Setiap *stage* terdiri dari sejumlah *residual block* yang memproses *feature map* pada resolusi spasial tertentu. Menurut (He *et al.* 2016), sebuah *residual block* mendefinisikan pemetaan output sebagai

$$\Psi(x, \zeta) = \int_{f(x,y) \leq \zeta} p(y) dy, \quad (1)$$

dengan x adalah input *block*, y adalah output *block*, dan $F(x, \{W_i\})$ adalah fungsi residu yang dipelajari oleh *layer* konvolusi dalam *block* tersebut. *Shortcut connection* bekerja dengan menyalurkan input x langsung menuju output *block*. Beberapa *layer* konvolusi di dalam *block* bertugas mempelajari fungsi residual $F(x, \{W_i\})$ yang kemudian, hasil dari fungsi residual tersebut dijumlahkan dengan input awal sehingga menghasilkan pemetaan akhir

$$y = F(x) + x. \quad (2)$$

Jaringan tidak lagi belajar pemetaan $y = H(x)$ secara langsung dari nol, melainkan cukup mempelajari fungsi residunya, yaitu perubahan kecil yang diperlukan terhadap input seperti pada Persamaan (3)

$$F(x) = H(x) - x. \quad (3)$$

Ditambahkan lapisan klasifikasi untuk tugas klasifikasi empat kelas penyakit tanaman padi. Diterapkan *Global Average Pooling 2D* (GAP) untuk mereduksi *feature map* dari *convolution* 5 menjadi vektor satu dimensi dengan mengambil rata-rata tiap *channel* yang didefinisikan

$$GAP_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W S_c(i, j), \quad c = 1, 2, \dots, C, \quad (4)$$

dengan $S_c(i, j)$ adalah nilai pada posisi (i, j) di *channel* ke- c . GAP secara drastis mengurangi jumlah parameter karena tidak ada bobot yang perlu dipelajari pada lapisan ini (Huang et al. 2025). Dilanjutkan, lapisan *fully connected* dengan 256 neuron diikuti oleh fungsi aktivasi ReLU yang dinyatakan pada Persamaan (5)

$$\text{ReLU}(z) = \max(0, z) = \begin{cases} z, & \text{jika } z > 0 \\ 0, & \text{jika } z \leq 0 \end{cases}. \quad (5)$$

Kemudian, diikuti oleh L2 regularization yang didefinisikan sebagai (Goodfellow et al. 2016)

$$L_{\text{regularisasi}} = L_{CE} + \lambda \sum_l \|W^{(l)}\|_F^2. \quad (6)$$

Diterapkan *dropout* sebesar $p = 0.5$ untuk mencegah *overfitting*. Kemudian diakhiri dengan lapisan output dengan 4 neuron dan fungsi aktivasi softmax yang didefinisikan sebagai

$$\text{Softmax}(z_k) = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}}, \quad k = 1, 2, \dots, K. \quad (7)$$

5) Pelatihan model

Pelatihan model dilakukan dengan penerapan *early stopping* untuk menghentikan pelatihan secara otomatis sebelum mencapai *epoch* maksimum dengan *monitor validation loss*, *patience* = 10, dan fungsi *restore best weight* yang berfungsi untuk mengembalikan bobot model ke kondisi terbaik yang dicapai selama proses pelatihan. *Epoch* maksimum yang digunakan selama pelatihan, yaitu 50 dengan *batch size* 64.

a. *Class weight*

Class weight diterapkan pada fungsi *loss* selama pelatihan dengan formula

$$w_j = \frac{n_{total}}{n_{kelas} \times n_j}, \quad (8)$$

dengan w_j adalah bobot untuk kelas j , n_{total} adalah total seluruh sampel data latih, n_{kelas} adalah jumlah kelas, dan n_j adalah jumlah sampel pada kelas j . Fungsi *loss* yang digunakan adalah *categorical cross-entropy* dengan formula

$$L(y, \hat{y}) = - \sum_{i=1}^c y_i \log(\hat{y}_i). \quad (9)$$

b. Algoritma *optimizer*

Digunakan dua jenis *optimizer*, yaitu Adam dengan pembaruan parameter seperti berikut (Kingma dan Ba 2015)

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t, \quad (10)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2, \quad (11)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t}, \quad (12)$$

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \varepsilon}, \quad (13)$$

dengan *learning rate* 0.0001, $\beta_1 = 0.9$, $\beta_2 = 0.999$, dan $\varepsilon = 1 \times 10^{-7}$. Kemudian, *optimizer* SGD-M dengan pembaruan parameter seperti berikut (Liu *et al.* 2020)

$$m^k = \beta m^{k-1} + (1 - \beta) \tilde{g}^k, \quad (14)$$

$$x^{k+1} = x^k - \alpha m^k. \quad (15)$$

dengan *learning rate* 0.001 dan momentum 0.9.

c. Skenario

- i. Adam tanpa *class weight*
- ii. Adam dengan penambahan *class weight*
- iii. SGD-M tanpa *class weight*
- iv. SGD-M dengan penambahan *class weight*

6) Evaluasi model

Evaluasi model dilakukan menggunakan *confusion matrix* sebagai representasi visual dari hasil prediksi model pada data uji. Evaluasi kinerja model klasifikasi berdasarkan indikator *accuracy*, *precision*,

recall, dan F1-score.

3. Hasil dan Pembahasan

3.1 Distribusi Data

Distribusi data per kelas pada setiap subset setelah pembagian data disajikan pada Tabel 1.

Tabel 1: Distribusi data.

Kelas	<i>Training</i>	<i>Validation</i>	<i>Testing</i>	Total
Bacterial blight	1.013	254	317	1584
Blast	922	230	288	1440
Brown spot	1.024	256	320	1600
Tungro	837	209	262	1308
Total	3.796	949	1187	5932

Menurut Kumar *et al.* (2022) rasio ketidakseimbangan kelas dapat dihitung dengan membagi jumlah sampel kelas terbanyak dan jumlah sampel kelas tersedikit, sehingga pada penelitian ini diperoleh

$$Rasio = \frac{1.600}{1.308} = 1.22. \quad (16)$$

Nilai ini menunjukkan bahwa ketidakseimbangan kelas pada dataset tergolong ringan. Ketidakseimbangan kelas pada dataset menyebabkan fungsi objektif *categorical cross-entropy* cenderung mempelajari kelas mayoritas karena nilai gradien yang dipropagasi balik secara proporsional bergantung pada frekuensi kemunculan kelas dalam setiap *mini-batch*.

3.2 Perhitungan *Class Weight*

Nilai *class weight* dihitung menggunakan formula seperti pada Persamaan (8) berdasarkan data latih yang berjumlah 3.794 citra dan 4 kelas. Hasil perhitungan untuk masing-masing kelas adalah sebagai berikut

$$w_{Bacterial\ blight} = \frac{3.796}{4 \times 1.013} = \frac{3.796}{4.052} \approx 0.9368, \quad (17)$$

$$w_{Blast} = \frac{3.796}{4 \times 922} = \frac{3.796}{3.688} \approx 1.0293, \quad (18)$$

$$w_{Brown\ spot} = \frac{3.796}{4 \times 1.024} = \frac{3.796}{4.096} \approx 0.9268, \quad (19)$$

$$w_{Tungro} = \frac{3.796}{4 \times 837} = \frac{3.796}{3.348} \approx 1.1338. \quad (20)$$

Dari hasil perhitungan diatas terlihat bahwa tungro mendapat bobot tertinggi sebesar 1.1338 karena memiliki jumlah data latih terdikit,

sedangkan brown spot mendapat bobot terendah sebesar 0.9268 karena memiliki jumlah data terbanyak.

3.3 Pelatihan dan Evaluasi Model

Penelitian ini menggunakan data sekunder berupa *daily adjusted closing price* pada saham konstituen indeks IDX30 yang diperoleh melalui *Yahoo Finance* untuk periode pengamatan dari 1 Februari 2023 hingga 28 Februari 2025. Setelah dilakukan penyaringan emiten tidak aktif dan penyelarasan kalender perdagangan, diperoleh rentang observasi seragam sebanyak 493 hari perdagangan untuk setiap saham. Informasi pendukung seperti kode saham, nama perusahaan, dan tanggal pencatatan diperoleh melalui situs resmi Bursa Efek Indonesia (BEI).


Setelah dilakukan pra-pemrosesan data, pembagian data, perhitungan *class weight* pada setiap kelas, dan augmentasi data untuk data latih, akan dibangun model ResNet-50 menggunakan teknik *transfer learning* dan *fine-tuning*. Kemudian, model yang dibangun akan di evaluasi dengan metrik evaluasi *accuracy*, *precision*, *recall*, dan *F1-score*.

Tabel 2: Keseluruhan metrik evaluasi skenario.

Skenario	Accuracy	Precision	Recall	F1-score
Adam tanpa <i>class weight</i>	98,82%	98,86%	98,85%	98,85%
Adam dengan <i>class weight</i>	98,99%	99,00%	99,03%	99,01%
SGD-M tanpa <i>class weight</i>	98,32%	98,45%	98,28%	98,33%
SGD-M dengan <i>class weight</i>	98,57%	98,65%	98,57%	98,60%


Berdasarkan Tabel 2, pengujian tanpa menggunakan *class weight* menunjukkan bahwa Adam mengungguli dengan *accuracy* 98,82% dan *macro F1-score* 98,85%, sedangkan SGD-M memperoleh *accuracy* 98,32% dan *macro F1-score* 98,33%. Pengujian menggunakan *class weight* menunjukkan mengalami kenaikan *accuracy* dan *macro F1-score* pada kedua *optimizer*, yaitu pada Adam *accuracy* sebesar 98,99% dan *macro F1-score* 99,01%, sedangkan SGD-M *accuracy* sebesar 98,57% dan *macro F1-score* 98,60%. Meskipun peningkatan pada kedua *optimizer* tidak signifikan, yang kemungkinan disebabkan oleh rasio ketidakseimbangan kelas pada dataset yang tergolong rendah, penggunaan *class weight* mengindikasikan memberikan dampak positif dalam membantu model mengklasifikasikan data secara lebih adil dan merata di setiap kelasnya. Selain itu, Adam mengungguli SGD-M di keempat skenario. Hal ini berkaitan dengan pembaruan parameter pada kedua *optimizer*. Adam mengadaptasi *learning rate* secara individual untuk setiap parameter dengan memanfaatkan estimasi momen pertama $\hat{m}_t$ dan momen kedua $\hat{v}_t$ dari gradien, sehingga

pembaruan parameter pada setiap langkah optimasi menjadi lebih terarah dan efisien.



Gambar

2: *Confusion matrix* (a) skenario 1: Adam tanpa *class weight* dan (b) skenario 3: SGD-M tanpa *class weight*



Gambar 3: *Confusion matrix* (a) skenario 2: Adam dengan *class weight* dan (b) skenario 4: SGD-M dengan *class weight*

Berdasarkan Gambar 2 dan Gambar 3, kelas tungro menunjukkan konsistensi prediksi sempurna di seluruh skenario, yang mengindikasikan bahwa fitur tekstural dan karakteristik visualnya sangat diskriminatif sehingga menghasilkan representasi yang terpisah secara ideal pada ruang fitur dimensi tinggi hasil ekstraksi lapisan *Global Average Pooling* di ruang $\mathbb{R}^{2048}$. Sebaliknya, pola kesalahan prediksi yang dominan terjadi antara kelas blast dan bacterial blight, model kerap salah mengkalsifikasikan blast sebagai bacterial blight. Hal ini mengindikasikan bahwa kedua kelas ini berbagi karakteristik visual pada saluran warna tertentu, menyebabkan vektor fitur keduanya memiliki jarak kosinus yang lebih kecil di ruang fitur tersebut. Selain itu, hal ini kemungkinan terjadi karena hasil dari augmentasi data yang dilakukan pada proses pelatihan.

4. Simpulan dan Saran

Penelitian ini telah mengaplikasikan model ResNet-50 dengan teknik *transfer learning* dan *fine-tuning* untuk mengklasifikasikan 4 jenis penyakit tanaman padi, yaitu bacterial blight, blast, brown spot, dan tungro. Setelah dilakukan evaluasi pada setiap skenario, diperoleh skenario terbaik, yaitu *optimizer* Adam dengan penambahan *class weight* yang memperoleh *accuracy* sebesar 98,99% dan *macro F1-score* 99,01%. Penerapan *class weight* memodifikasi fungsi *categorical cross-entropy* menjadi fungsi *loss* dengan penambahan bobot, sehingga kontribusi *loss* setiap kelas bergeser sesuai dengan bobotnya. Penggunaan *class weight* meningkatkan *accuracy* pada model dengan Adam, yaitu 98,82% menjadi 98,99% dan pada model dengan SGD-M, yaitu 98,32% menjadi 98,57%. Adam secara konsisten mengungguli SGD-M pada seluruh metrik evaluasi dan kedua kondisi *class weight*. Keunggulan Adam terdapat dari mekanisme *adaptive learning rate* per parameter yang memungkinkan setiap bobot jaringan diperbarui dengan langkah yang disesuaikan berdasarkan riwayat gradiennya.

Meskipun hasil yang diperoleh sudah cukup baik, masih ada ruang untuk pengembangan lebih lanjut dalam tugas klasifikasi citra, seperti penerapan metode penanganan ketidakseimbangan kelas lainnya seperti SMOTE (*Syntetic Minority Oversampling Technique*), *undersampling*, dan *oversampling*. Selain itu, menerapkan pada dataset dengan ketidakseimbangan yang lebih tinggi untuk melihat sejauh mana *class weight* dapat mempertahankan performa model ketika distribusi kelas sangat tidak seimbangan.

Daftar Pustaka

- Azizi MMF, Lau HY. 2022. Advanced Diagnostic Approaches Developed For The Global Menace of Rice Diseases: a Review. *Canadian Journal of Plant Pathology*. 44(5):627–651. doi:10.1080/07060661.2022.2053588.
- Badan Pusat Statistik. 2025. Pada 2024, luas panen padi mencapai sekitar 10,05 juta hektare dengan produksi padi sebanyak 53,14 juta ton gabah kering giling (GKG). *Badan Pusat Statistik*, siap terbit. [diakses 2026 Mei 13]. <https://www.bps.go.id/id/pressrelease/2025/02/03/2414/pada-2024--luas-panen-padi-mencapai-sekitar-10-05-juta-hektare-dengan-produksi-padi-sebanyak-53-14-juta-ton-gabah-kering-giling--gkg--.html>.
- Bahtiar A, Hutomo MIP, Widiyanto A, Khomsah S. 2025. Class Weighting Approach for Handling Imbalanced Data on Forest Fire Classification Using EfficientNet-B1. *JISKA (Jurnal Informatika Sunan Kalijaga)*. 10(1):63–73. doi:10.14421/jiska.2025.10.1.63-73.
- Goodfellow I, Bengio Y, Courville A. 2016. *Deep Learning*. MIT Press.

- Hastari D, Winanda S, Pratama AR, Nurhaliza N, Ginting ES. 2024. Application of Convolutional Neural Network ResNet-50 V2 on Image Classification of Rice Plant Disease. *Public Research Journal of Engineering, Data Technology and Computer Science*. 1(2). doi:10.57152/predatecs.v1i2.865.
- He K, Zhang X, Ren S, Sun J. 2016. Deep Residual Learning for Image Recognition. Di dalam: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE. hlm 770–778.
- Huang C-C, Chang C-C, Chang C-M. 2025. Evaluating convolutional neural networks using residual blocks and global average pooling techniques for predicting sediment concentration. *Sci Rep*. 15(1):35278. doi:10.1038/s41598-025-19161-w.
- Kingma DP, Ba J. 2015. Adam: A Method for Stochastic Optimization. Di dalam: *3rd International Conference for Learning Representations*. San Diego.
- Kumar V, Lalotra GS, Sasikala P, Rajput DS, Kaluri R, Lakshmana K, Shorfuazzaman M, Alsufyani A, Uddin M. 2022. Addressing Binary Classification over Class Imbalanced Clinical Datasets Using Computationally Intelligent Techniques. *Healthcare*. 10(7):1293. doi:10.3390/healthcare10071293.
- Liu Y, Gao Y, Yin W. 2020. An Improved Analysis of Stochastic Gradient Descent with Momentum. Di dalam: *34th Conference on Neural Information Processing Systems (NeurIPS 2020)*. Vancouver, Canada: NeurIPS.
- Ning H, Liu S, Zhu Q, Zhou T. 2023. Convolutional Neural Network in Rice Disease Recognition: Accuracy, Speed and Lightweight. *Front Plant Sci*. 14:1269371. doi:10.3389/fpls.2023.1269371.
- Shorten C, Khoshgoftaar TM. 2019. A survey on Image Data Augmentation for Deep Learning. *J Big Data*. 6(1):60. doi:10.1186/s40537-019-0197-0.
- Tan C, Sun F, Kong T, Zhang W, Yang C, Liu C. 2018. A Survey on Deep Transfer Learning. hlm 270–279.
- Zhuang F, Qi Z, Duan K, Xi D, Zhu Y, Zhu H, Xiong H, He Q. 2021. A Comprehensive Survey on Transfer Learning. *Proceedings of the IEEE*. 109(1):43–76. doi:10.1109/JPROC.2020.3004555.