

Article history:

Received: Jun 2, 2025

Published: Dec 6, 2025

Klasifikasi Kekeringan dan Penyakit pada Daun Padi Berdasarkan Ekstraksi Ciri Warna dan Tekstur Menggunakan CSPDarknet

¹⁾Abdul Jabbar Robbani ²⁾Aditya Dwi Putro Wicaksono ³⁾Dedy Agung Prabowo

^{1,3)}Fakultas Informatika, Telkom University Purwokerto

email: ¹ abduljabbarrobbani@student.telkomuniversity.ac.id, ²adityaw@telkomuniversity.ac.id,

³dedyaprabowo@telkomuniversity.ac.id

Abstract

The decline in rice productivity in Indonesia is often caused by drought and leaf diseases that are difficult to detect early. This condition requires a technology-based classification system that is able to provide fast and accurate diagnosis as support for decision making in the agricultural sector. This study aims to develop a rice leaf image classification model using the CSPDarknet architecture, with a color and texture feature extraction approach. The dataset used is the result of primary documentation that has gone through an augmentation process to increase the diversity of training data. The model architecture consists of a CSPDarknet backbone combined with a Cross-stage Partial Bottleneck with two Convolutions (C2f) block, Spatial Pyramid Pooling - Fast (SPPF), Global Average Pooling, and dropout to improve model generalization. Training was carried out using the Stratified 5-Fold Cross-Validation method and three optimizer variations, namely Stochastic Gradient Descent (SGD), Adam, and AdamW. The experimental results showed that the best model combination was achieved with the AdamW optimizer, with an average accuracy value of 99.72%, precision of 99.73%, recall of 99.72%, and F1-score of 99.72%. These findings indicate that the proposed classification approach is able to effectively distinguish healthy, diseased, and drought-affected leaves. In the future, this model has the potential to be further developed through the integration of Raspberry Pi-based Internet of Things (IoT) devices for real-time monitoring of plant conditions in the field.

Keywords: Rice Leaf Classification, Drought, Plant Disease, CSPDarknet, Color Extraction, Texture Extraction

Abstrak

Penurunan produktivitas padi di Indonesia kerap disebabkan oleh kekeringan dan penyakit daun yang sulit terdeteksi secara dini. Kondisi ini menuntut adanya sistem klasifikasi berbasis teknologi yang mampu memberikan diagnosis cepat dan akurat sebagai dukungan bagi pengambilan keputusan di sektor pertanian. Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra daun padi menggunakan arsitektur CSPDarknet, dengan pendekatan ekstraksi ciri warna dan tekstur. Dataset yang digunakan merupakan hasil dokumentasi primer yang telah melalui proses augmentasi guna meningkatkan keragaman data latih. Arsitektur model terdiri dari backbone CSPDarknet yang dikombinasikan dengan Cross-stage Partial Bottleneck with two Convolutions (C2f) block, Spatial Pyramid PoolingFast (SPPF), Global Average Pooling, dan dropout untuk meningkatkan generalisasi model. Pelatihan dilakukan dengan metode Stratified 5-Fold Cross-Validation serta tiga variasi optimizer, yaitu Stochastic Gradient Descent (SGD), Adam, dan AdamW. Hasil eksperimen menunjukkan bahwa kombinasi model terbaik dicapai dengan optimizer AdamW, dengan nilai akurasi rata-rata 99,72%, presisi 99,73%, recall 99,72%, dan F1-score 99,72%. Temuan ini menunjukkan bahwa pendekatan klasifikasi yang diusulkan mampu membedakan daun sehat, terserang penyakit, dan mengalami kekeringan secara efektif. Ke depan, model ini berpotensi dikembangkan lebih lanjut melalui integrasi perangkat Internet of Things (IoT) berbasis Raspberry Pi untuk pemantauan kondisi tanaman secara real-time di lapangan.

Kata Kunci: Klasifikasi Daun Padi, Kekeringan, Penyakit Tanaman, CSPDarknet, Ekstraksi Warna, Ekstraksi Tekstur

1. INTRODUCTION

Padi merupakan komoditas strategis dalam ketahanan pangan global dan sumber utama konsumsi bagi mayoritas penduduk dunia [1]. Di Indonesia, beras tidak hanya berfungsi sebagai bahan pokok, tetapi juga berperan penting dalam menjaga stabilitas sosial, ekonomi, dan politik nasional [2]. Untuk memenuhi permintaan konsumsi yang terus meningkat, produksi padi harus ditingkatkan baik dari segi kuantitas maupun kualitas [3]. Namun, data dari Badan Pusat Statistik Provinsi Jawa Tengah menunjukkan adanya penurunan luas panen sebesar 2,86% pada tahun 2023 dibanding tahun sebelumnya [4], menandakan tantangan serius dalam sektor pertanian. Faktor utama yang mempengaruhi produktivitas adalah kondisi lingkungan, seperti perubahan iklim ekstrem yang menyebabkan kekeringan dan curah hujan berlebihan, serta serangan organisme pengganggu tanaman yang mengakibatkan penurunan hasil panen [5]. Penurunan produksi nasional sebesar 0,23% pada periode Januari-September 2023, diperparah oleh fenomena El Niño di wilayah penghasil padi seperti Jawa Tengah, mempertegas urgensi penanganan masalah ini [6].

Identifikasi dini penyakit dan kekeringan pada daun padi masih mengandalkan metode manual yang bergantung pada pengamatan visual serta pengalaman petani, yang kerap bersifat subjektif dan kurang akurat [7]. Kondisi ini diperparah di wilayah seperti Desa Kaliori, Kabupaten Banyumas, di mana mayoritas petani berusia lanjut dan menggunakan alat tradisional, sebagaimana disampaikan oleh Ketua Gapoktan setempat, Bapak Supardi [8]. Gejala awal seperti bercak warna tidak normal atau pola yang tidak lazim pada daun merupakan indikator penting yang sulit terdeteksi secara dini, sehingga penyakit dan kerusakan dapat menyebar dengan cepat [9][10]. Berbagai pendekatan berbasis *machine learning* telah dikembangkan untuk mengatasi masalah ini, termasuk *Support Vector Machine* (SVM) [11], *Convolutional Neural Network* (CNN) [12], *transfer learning* [13], *fuzzy logic* [14], dan bioinformatika [15]. Meski demikian, sebagian besar metode tersebut masih terbatas dalam kecepatan dan akurasi deteksi pada kondisi lapangan yang kompleks dan variatif.

Untuk mengatasi keterbatasan tersebut, penelitian ini mengusulkan penggunaan arsitektur CSPDarknet sebagai model klasifikasi citra daun

padi yang memiliki efisiensi tinggi dan kemampuan ekstraksi ciri mendalam melalui mekanisme *cross stage partial connection*. Model ini dilengkapi dengan blok *cross-stage Partial Bottleneck with two Convolutions* (C2f), modul *Spatial Pyramid Pooling Fast* (SPPF), dan *Global Average Pooling* (GAP) untuk mendukung klasifikasi multi-kelas secara optimal. *Dataset* yang digunakan berasal dari pengambilan data langsung di Desa Kaliori dan telah mengalami augmentasi untuk meningkatkan variasi data. Pelatihan dilakukan menggunakan teknik *stratified 5-fold cross-validation* guna menjamin stabilitas dan keandalan evaluasi performa model. Keunggulan CSPDarknet dibandingkan metode konvensional terletak pada akurasi tinggi, efisiensi komputasi, dan kemudahan integrasi dengan sistem monitoring berbasis perangkat lunak ringan. Diharapkan, hasil penelitian ini dapat menjadi solusi efektif dalam mendeteksi dini kondisi daun padi serta mendukung implementasi teknologi pertanian presisi berbasis *Internet of Things* (IoT) yang adaptif dan berkelanjutan.

2. LITERATURE REVIEW

Klasifikasi kondisi daun padi berbasis citra digital menunjukkan perkembangan pesat, seiring meningkatnya kebutuhan akan sistem deteksi dini dalam pertanian presisi. Pendekatan deep learning, khususnya *Convolutional Neural Network* (CNN), banyak dimanfaatkan karena kemampuannya dalam mengenali pola visual kompleks. Metode YOLO dengan *backbone CSPDarknet* semakin relevan berkat efisiensi ekstraksi ciri melalui *cross stage partial connections*. Berbagai studi sebelumnya memperlihatkan peningkatan akurasi klasifikasi penyakit tanaman, namun juga menyoroti keterbatasan metodologis dan tantangan implementasi di lapangan.

YOLOv8 telah digunakan untuk mendeteksi empat kondisi daun padi, yakni brown spot, hispa, leaf blast, dan daun sehat, menggunakan *dataset rice diseases image* sebanyak 3.216 gambar. Model YOLOv8s memberikan performa mAP50 tertinggi, yaitu 97,9%, melampaui YOLOv5 dan YOLOv4 dalam hal kecepatan dan akurasi, meskipun validasi lebih lanjut pada data lapangan tetap diperlukan [16]. Sebuah pendekatan *real-time* menggunakan YOLOv4-Tiny dan Raspberry Pi juga dikembangkan untuk klasifikasi penyakit daun padi secara langsung melalui video *livestream* berbasis *WebSocket*. Meskipun akurasi

rata-rata mencapai 80%, keterbatasan perangkat keras menjadi tantangan dalam implementasi di lapangan [17].

Penelitian lain menggunakan YOLOv5 untuk mendeteksi lima jenis penyakit dari citra yang dikumpulkan di Feni, Bangladesh. Dengan 1.500 gambar yang diaugmentasi menggunakan *Roboflow*, model ini mencapai *precision* 90%, namun *recall* masih rendah sebesar 67%, menandakan sensitivitas model terhadap gejala penyakit masih perlu ditingkatkan [18]. Sementara itu, strategi kombinatorik dengan menggabungkan YOLOv7 dan *active deep learning* menghasilkan *F1-score* sebesar 0,76, namun cakupan wilayah dan varietas yang terbatas menghambat generalisasi model [19].

Selain itu, pendekatan klasifikasi objek berbasis YOLO diterapkan untuk identifikasi varietas beras menggunakan YOLOv3. Hasil akurasi mencapai 100% pada citra tidak bertumpuk, namun turun menjadi 60% saat objek saling tumpang tindih, mengindikasikan perlunya penguatan terhadap kompleksitas latar belakang visual [20]. Penggunaan modul CFAN yang dipadukan dengan YOLOv5 juga menunjukkan peningkatan signifikan dalam akurasi klasifikasi daun tomat dan kentang pada *dataset PlantVillage*, mencapai akurasi 99,55% dan *F1-score* 96%. Namun, keterbatasan latar belakang tetap menjadi hambatan utama dalam implementasi pada kondisi riil [21].

Pengembangan berbasis *mobile* juga dilakukan untuk deteksi penyakit tanaman secara *real-time* di perangkat *Android*. Salah satu studi memanfaatkan berbagai varian YOLO dan menghasilkan performa terbaik dengan YOLOv8n (mAP 99,04%). Model ini berhasil diintegrasikan ke dalam aplikasi *Android* menggunakan *TensorFlow Lite*, yang memungkinkan deteksi langsung melalui kamera ponsel, meskipun tantangan terkait stabilitas dan cakupan kelas masih perlu disempurnakan [22].

Dari berbagai pendekatan tersebut, terlihat bahwa keberhasilan klasifikasi sangat dipengaruhi oleh desain arsitektur, strategi ekstraksi ciri, dan keberagaman data pelatihan. Namun, masih terdapat tantangan berupa nilai *recall* yang belum optimal, keterbatasan pengujian pada kondisi nyata, serta kurangnya eksplorasi ciri visual seperti warna dan tekstur. Pendekatan sebelumnya juga belum sepenuhnya

mengintegrasikan ciri tersebut secara menyeluruh dalam pelatihan model, sehingga membatasi ketepatan klasifikasi gejala.

Untuk menjawab tantangan ini, penelitian ini mengusulkan pendekatan klasifikasi menggunakan *CSPDarknet Classifier* yang telah dimodifikasi secara struktural. Modifikasi mencakup penambahan blok C2f, SPPF, dan GAP untuk meningkatkan efisiensi klasifikasi multi-kelas. *Dataset* dikumpulkan secara primer dari Desa Kaliori, Kabupaten Banyumas, mencakup tiga kelas utama: daun sehat, bercak daun coklat sempit, dan gejala kekeringan. Proses augmentasi diterapkan guna memperluas variasi visual dan mendukung generalisasi. Dengan pendekatan ini, diharapkan model dapat memberikan kontribusi nyata bagi sistem pendukung keputusan dalam penerapan pertanian presisi.

3. METHOD

Penelitian ini menerapkan pendekatan computer vision dengan model *CSPDarknet Classifier*, yaitu arsitektur CNN yang dimodifikasi menggunakan blok *Cross-stage Partial Bottleneck with two Convolutions* (C2f), *Spatial Pyramid Pooling Fast* (SPPF), dan *Global Average Pooling* (GAP) untuk mengekstraksi ciri warna dan tekstur daun padi. *Dataset* primer dikumpulkan dari Desa Kaliori dalam tiga kelas, yaitu daun sehat, bercak coklat sempit, dan gejala kekeringan. Data diproses melalui *resizing* dan augmentasi untuk meningkatkan variasi dan mengurangi *overfitting*. Pelatihan dilakukan menggunakan *stratified 5-fold cross-validation*, sementara parameter seperti *epoch*, *batch size*, dan *optimizer* disesuaikan untuk performa optimal. Evaluasi model menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1 score*, dilanjutkan dengan analisis hasil untuk menilai efektivitas model dan memberikan rekomendasi pengembangan.

Teknik Pengumpulan Data

Data dikumpulkan secara primer melalui dokumentasi langsung kondisi daun padi di Desa Kaliori pada 26 Maret 2024, mencakup tiga kategori: bercak coklat sempit, gejala kekeringan, dan daun sehat. Pengambilan gambar dilakukan menggunakan kamera Redmi Note 8 (48 MP) dengan pendampingan Ketua Gapoktan setempat untuk memastikan keakuratan label. Total 120 gambar (.png) diperoleh, masing-masing kelas

terdiri dari 40 citra, dan digunakan sebagai bahan dasar untuk tahap pra-pemrosesan dalam pelatihan model. sebagai contoh dari citra yang terdokumentasikan ditampilkan pada Gambar 1 sebagai *sample* dataset yang mewakili masing-masing kelas daun




Gambar 1 *Sample* Dataset

Teknik Preprocessing Data

Setelah data terkumpul, dilakukan *preprocessing* untuk menyiapkan citra sesuai kebutuhan model CSPDarknet, meliputi *resizing*, pelabelan, augmentasi, serta pembagian data menjadi set pelatihan dan validasi

A. Resizing Gambar


Langkah awal *preprocessing* adalah mengubah ukuran seluruh citra menjadi 224×224 piksel untuk memenuhi standar input CSPDarknet. Proses ini dilakukan menggunakan layanan daring *iloveimg* agar dimensi seragam dan kualitas tetap terjaga, sehingga memudahkan model dalam mengekstraksi ciri visual. Contoh hasil *resizing* ditampilkan pada Gambar 2.



Gambar 2 *Sample* Resizing Dataset

B. Pemberian Label


Setelah *resizing*, citra diberi label menggunakan *platform* roboflow. Label diberikan sesuai tiga kelas utama sehat, kering, bercak coklat sempit. *Label* disimpan dalam format .txt. Contoh proses pelabelan ditunjukkan pada Gambar 3.



Gambar 3 *Sample* Labelling

C. Augmentasi Gambar

Augmentasi diterapkan untuk meningkatkan keberagaman data dan daya generalisasi model. Teknik yang digunakan meliputi *grid distortion*, *elastic transform*, *Contrast Limited Adaptive Histogram Equalization* (CLAHE), *mixup*, dan *cutmix*. Teknik ini meniru variasi alami bentuk, pencahayaan, serta memadukan gambar untuk memperkaya pola visual. Hasil augmentasi dapat dilihat pada Gambar 4.



Gambar 4 *Sample* Hasil Teknik Augmentasi

D. Pembagian Dataset

Dataset diproses di roboflow lalu diimpor ke google colab dalam struktur folder yang sesuai. Pembagian data dilakukan dengan *stratified 5-fold cross-validation*, menggunakan rasio 80% data pelatihan dan 20% validasi pada tiap *fold*. Pendekatan ini bertujuan mengevaluasi model secara menyeluruh dan mengurangi risiko *overfitting*.


Implementasi Model CSPDarknet

Tahap implementasi model dilakukan setelah seluruh proses awal, mulai dari identifikasi permasalahan hingga pra-pemrosesan data, selesai dilaksanakan. Tujuan utamanya adalah membangun model klasifikasi citra berbasis deep learning yang mampu mengenali kondisi daun padi berdasarkan ciri warna dan tekstur. Model yang digunakan adalah CSPDarknet, sebuah arsitektur konvolusional yang menggabungkan *residual learning* dan *cross-stage partial connections* untuk meningkatkan efisiensi

ekstraksi ciri dan menurunkan kompleksitas komputasi.

Dataset diperoleh dari *platform* Roboflow, yang telah melalui proses pelabelan otomatis, augmentasi citra, dan konversi ke format klasifikasi gambar. Data diimpor secara langsung melalui API proyek dan dikelola menggunakan kelas *PaddyDataset*. Kelas ini mendukung transformasi data dengan modul *torchvision.transforms*, termasuk *color jitter* (*hue* 1,5%, *saturation* 40%, *brightness* 30%), rotasi 15°, translasi hingga 10%, dan skala 80–120%. Seluruh citra kemudian diubah ke resolusi 224×224 piksel dan dikonversi menjadi tensor untuk keperluan pelatihan.

Arsitektur CSPDarknet yang diterapkan dimulai dengan konvolusi awal untuk menghasilkan 32 kanal ciri dasar, diikuti beberapa blok *Cross-stage Partial Bottleneck with two Convolutions* (C2f) dengan aktivasi SiLU dan proses *downsampling* bertahap melalui *max pooling* 2×2. Modul *Spatial Pyramid Pooling Fast* (SPPF) digunakan untuk menangkap ciri spasial multi-skala, dilanjutkan dengan konvolusi 1×1, GAP adaptif, dan *dropout* (p=0.5). Lapisan akhir adalah *fully connected* dengan tiga *neuron output* untuk klasifikasi tiga kelas, yaitu Daun Padi Sehat, Daun Padi Kekeringan, dan Bercak Daun Coklat Sempit. Struktur ini divisualisasikan pada Gambar 5.



Gambar 5 Arsitektur Cspdarknet Yang Telah Disesuaikan

Untuk mengevaluasi performa model, dilakukan pengujian berdasarkan tiga skenario percobaan yang dibedakan berdasarkan jenis fungsi optimasi (*optimizer*). Setiap skenario menggunakan *5-fold stratified cross-validation*, 50 *epoch* pelatihan, dan *batch size* 16. Tabel berikut merangkum konfigurasi yang digunakan:

Tabel 1 Skenario Percobaan

Skenario	Optimizer	Epoch
1	SGD	50
2	Adam	50
3	AdamW	50

Setiap skenario dirancang untuk menilai pengaruh algoritma optimasi terhadap performa model dalam klasifikasi citra daun padi. Evaluasi mencakup metrik *accuracy*, *precision*, *recall*, dan *f1 score*, yang dihitung pada setiap *fold* dan dirata-ratakan untuk memperoleh gambaran performa keseluruhan. Dengan demikian, proses ini bertujuan mengidentifikasi konfigurasi terbaik yang dapat meningkatkan generalisasi dan stabilitas model dalam menghadapi variasi data.

Evaluasi Performa Model

Setelah pelaksanaan skenario percobaan, tahap selanjutnya adalah mengevaluasi performa model CSPDarknet yang dilatih menggunakan skema *k-fold cross-validation*. Evaluasi ini bertujuan menilai kemampuan model dalam mengklasifikasikan kondisi daun padi secara akurat dan konsisten.

Empat metrik utama digunakan, yaitu *accuracy*, *precision*, *recall*, dan *f1 score*, yang masing-masing dihitung berdasarkan persamaan berikut:

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

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

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

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Accuracy mencerminkan ketepatan keseluruhan prediksi model, *Precision* mengukur seberapa tepat model dalam mengklasifikasikan kelas positif, sedangkan *recall* menilai kemampuannya dalam mendeteksi seluruh kasus positif. *F1 Score* digunakan untuk menyeimbangkan *precision* dan *recall*, khususnya saat distribusi kelas tidak merata.

Metrik dihitung pada setiap *fold* dan dirata-ratakan untuk mendapatkan gambaran performa umum. Analisis dilakukan untuk mengevaluasi pengaruh variasi jenis *optimizer* dan jumlah *epoch* terhadap nilai metrik, serta mengamati potensi *overfitting* atau *underfitting* berdasarkan fluktuasi performa antar *fold*. Dengan demikian, analisis ini bertujuan menentukan konfigurasi pelatihan terbaik bagi model CSPDarknet dalam klasifikasi daun padi.

4. HASIL DAN PEMBAHASAN

Algoritma Model CSPDarknet

Penelitian ini melakukan evaluasi terhadap performa model klasifikasi daun padi menggunakan tiga skenario berdasarkan variasi algoritma optimasi, yaitu SGD, Adam, dan AdamW.

A. Skenario Pertama *Optimizer* SGD

Pada skenario pertama, model CSPDarknet dilatih menggunakan *optimizer* SGD. Evaluasi menunjukkan performa model sangat rendah dan cenderung stagnan pada seluruh *fold*. Hasil metrik per *fold* ditampilkan pada Tabel 2

Tabel 2 Hasil Evaluasi Per-Fold *Optimizer*

Fold	Akurasi	Presisi	Recall	F1-Score
1	0.3333	0.1111	0.3333	0.1667
2	0.3333	0.1111	0.3333	0.1667
3	0.3333	0.1111	0.3333	0.1667
4	0.3333	0.1111	0.3333	0.1667
5	0.3333	0.1111	0.3333	0.1667
Rata-rata	0.3333	0.1111	0.3333	0.1667

Seperti ditunjukkan pada Tabel 2, akurasi dan *F1-score* yang sangat rendah mengindikasikan bahwa model tidak mampu mempelajari representasi ciri dari dataset secara efektif. Hal ini didukung oleh Gambar 6, di mana grafik *loss* menunjukkan stagnansi nilai *train loss* dan *val loss* selama pelatihan.



Gambar 6 Grafik Rata-Rata *Train Loss* Dan *Val Loss* *Optimizer*

Stagnansi ini kemungkinan disebabkan oleh pengaturan *hyperparameter* (SGD) yang tidak optimal serta arsitektur model yang kurang mampu menangkap kompleksitas ciri visual daun padi. Oleh karena itu, perlu eksplorasi lebih lanjut terhadap *optimizer* alternatif.


B. Skenario Kedua *Optimizer* Adam

Skenario kedua mengimplementasikan *optimizer* Adam dengan konfigurasi yang sama. Hasil evaluasi menunjukkan peningkatan performa yang sangat signifikan dibandingkan skenario pertama, sebagaimana diringkas dalam Tabel 3.

Tabel 3 Hasil Evaluasi Per-Fold *Optimizer*

Fold	Accuracy	Precision	Recall	F1 Score
1	0.7778	0.8667	0.7778	0.7832
2	1.0000	1.0000	1.0000	1.0000
3	1.0000	1.0000	1.0000	1.0000
4	1.0000	1.0000	1.0000	1.0000
5	1.0000	1.0000	1.0000	1.0000
Rata-rata	0.9556	0.9733	0.9556	0.9566

Gambar 7 menunjukkan grafik *loss* per *epoch* yang stabil dengan tren penurunan signifikan pada awal pelatihan. Konvergensi antara *train loss* dan *val loss* menunjukkan bahwa model tidak mengalami *overfitting*.



Gambar 7 Grafik Rata-Rata *Train Loss* Dan *Val Loss* *Optimize*

Performa tinggi ini menunjukkan bahwa *optimizer* Adam mampu mengakomodasi distribusi data yang kompleks dan meningkatkan kapabilitas generalisasi model. Ini menandakan bahwa pendekatan ini cocok untuk deteksi otomatis pada skenario nyata.

C. Skenario Ketiga *Optimizer* AdamW


Pada skenario ketiga, digunakan *optimizer* AdamW yang menggabungkan keunggulan Adam dengan regularisasi *weight decay*. Tabel 4 merangkum hasil per *fold*, yang secara umum menunjukkan performa hampir sempurna.

Tabel 4 Hasil Evaluasi Per-Fold *Optimizer* Adamw

Fold	Accuracy	Precision	Recall	F1 Score
1	1.0000	1.0000	1.0000	1.0000
2	1.0000	1.0000	1.0000	1.0000
3	1.0000	1.0000	1.0000	1.0000
4	1.0000	1.0000	1.0000	1.0000

5	0.9861	0.9863	0.9861	0.9861
Rata-rata	0.9972	0.9973	0.9972	0.9972

Model menunjukkan akurasi dan presisi yang sangat tinggi di hampir semua *fold*. Grafik *loss* Gambar 8 memperkuat hasil tersebut dengan menunjukkan proses pelatihan yang efisien dan konvergen secara progresif.



Gambar 8 Grafik Rata-Rata *Train Loss* Dan *Val Loss* Optimizer Adamw

Dengan hasil ini, dapat disimpulkan bahwa konfigurasi pelatihan menggunakan AdamW memberikan keseimbangan terbaik antara akurasi tinggi, konvergensi cepat, dan kestabilan antar *fold*. Oleh karena itu, konfigurasi ini direkomendasikan sebagai pilihan utama dalam pengembangan sistem klasifikasi otomatis daun padi.

Analisis Perbandingan Antar Skenario

Dari ketiga skenario yang diuji, terlihat bahwa perubahan algoritma optimasi memberikan dampak signifikan terhadap performa klasifikasi. Optimizer (SGD) gagal memberikan generalisasi yang baik, sedangkan Adam meningkatkan akurasi secara signifikan. Namun, AdamW menghasilkan performa terbaik secara konsisten di seluruh *fold*.

Keunggulan AdamW tidak hanya terlihat pada nilai metrik evaluasi, tetapi juga dari tren grafik *loss* yang stabil dan konvergen. Ini menandakan bahwa pendekatan regularisasi *weight decay* pada AdamW berhasil mengurangi *overfitting* dan meningkatkan kemampuan adaptasi model terhadap data baru.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan dan mengevaluasi model *cross-stage partial darknet classifier* untuk klasifikasi daun padi berdasarkan ciri warna dan tekstur, menggunakan struktur *Cross-stage Partial Bottleneck with two Convolutions (C2f)*, *Spatial Pyramid Pooling Fast (SPPF)*, *Global Average Pooling*, dan *Dropout*. Evaluasi melalui *stratified 5-fold cross-validation* menunjukkan bahwa optimizer (SGD)

menghasilkan performa rendah (rata-rata akurasi 33,33%) karena ketidakmampuannya menangani kompleksitas model, sedangkan Adam memberikan peningkatan signifikan (akurasi 95,56%) berkat mekanisme pembaruan parameter yang adaptif. Optimizer AdamW menjadi yang terbaik, dengan akurasi rata-rata 99,72% serta kestabilan antar *fold* dan kemampuan regularisasi yang unggul. Dengan demikian, CSPDarknet Classifier menunjukkan kinerja optimal saat menggunakan algoritma optimisasi yang adaptif seperti AdamW, dan skenario ketiga dengan konfigurasi 50 *epoch* dan *batch size* 16 layak dijadikan acuan dalam penerapan klasifikasi daun padi di bidang pertanian presisi.

6. REFERENSI

- [1] R. C. Bautista and P. A. Counce, "An Overview of Rice and Rice Quality," *Cereal Foods World*, vol. 65, no. 5, 2020, doi: 10.1094/cfw-65-5-0052.
- [2] E. I. R. Rhofita, "Optimalisasi Sumber Daya Pertanian Indonesia untuk Mendukung Program Ketahanan Pangan dan Energi Nasional," *Jurnal Ketahanan Nasional*, vol. 28, no. 1, p. 82, 2022, doi: 10.22146/jkn.71642.
- [3] N. E. Budiayanta, M. Mulyadi, and H. Tanudjaja, "Sistem Deteksi Kemurnian Beras berbasis Computer Vision dengan Pendekatan Algoritma YOLO," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 6, no. 1, pp. 51–55, 2021, doi: 10.30591/jpit.v6i1.2309.
- [4] "Luas Panen dan Produksi Padi di Provinsi Jawa Tengah 2023 (Angka Sementara)," Badan Pusat Statistik Provinsi Jawa Tengah. [Online]. Available: <https://jateng.bps.go.id/pressrelease/2023/11/01/1458/luas-panen-dan-produksi-padi-di-provinsi-jawa-tengah-2023--angka-sementara-.html>
- [5] E. Rasmikayati, B. R. Saefudin, D. Rochdiani, and R. S. Natawidjaja, "Dinamika Respon Mitigasi Petani Padi di Jawa Barat dalam Menghadapi Dampak Perubahan Iklim serta Kaitannya dengan Pendapatan Usaha Tani," *Jurnal Wilayah dan Lingkungan*, vol. 8, no. 3, pp. 247–260, 2020, doi: 10.14710/jwl.8.3.247-260.
- [6] "Produksi Padi Tahun 2023 Mengalami Penurunan," BADAN PUSAT STATISTIK KABUPATEN PATI. [Online]. Available: <https://patikab.beta.bps.go.id/id/news/2023/10/16/518/produksi-padi-tahun-2023-mengalami-penurunan.html>
- [7] Z. Jiang, Z. Dong, W. Jiang, and Y. Yang, "Recognition of rice leaf diseases and wheat leaf diseases based on multi-task deep transfer learning," *Comput Electron Agric*, vol. 186, p. 106184, Jul. 2021, doi: 10.1016/j.compag.2021.106184.

- [8] S. Sudewi, A. Ala, B. Baharuddin, and M. F. BDR, "Keragaman Organisme Pengganggu Tanaman (OPT) pada Tanaman Padi Varietas Unggul Baru (VUB) dan Varietas Lokal pada Percobaan Semi Lapangan," *Agrikultura*, vol. 31, no. 1, p. 15, 2020, doi: 10.24198/agrikultura.v31i1.25046.
- [9] Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, and Galih Wasis Wicaksono, "Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1216–1222, 2021, doi: 10.29207/resti.v5i6.3607.
- [10] R. R. Rachmawati, "Smart Farming 4.0 Untuk Mewujudkan Pertanian Indonesia Maju, Mandiri, Dan Modern," *Forum penelitian Agro Ekonomi*, vol. 38, no. 2, p. 137, 2021, doi: 10.21082/fae.v38n2.2020.137-154.
- [11] A. Purnamawati, W. Nugroho, D. Putri, and W. F. Hidayat, "Deteksi Penyakit Daun pada Tanaman Padi Menggunakan Algoritma Decision Tree, Random Forest, Naïve Bayes, SVM dan KNN," *InfoTekJar: Jurnal Nasional Informatika dan Teknologi Jaringan*, vol. 5, no. 1, pp. 212–215, 2020, [Online]. Available: <https://doi.org/10.30743/infotekjar.v5i1.2934>
- [12] S. Ghosal and K. Sarkar, "Rice Leaf Diseases Classification Using CNN With Transfer Learning," in *2020 IEEE Calcutta Conference (CALCON)*, IEEE, Feb. 2020, pp. 230–236. doi: 10.1109/CALCON49167.2020.9106423.
- [13] 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.
- [14] A. Rifa'i and D. Mahdiana, "Image Processing for Diagnosis Rice Plant Diseases Using the Fuzzy System," in *2020 International Conference on Computer Science and Its Application in Agriculture (ICOSICA)*, IEEE, Sep. 2020, pp. 1–5. doi: 10.1109/ICOSICA49951.2020.9243274.
- [15] L. Muflikhah, Widodo, W. Mahmudy, and Solimun, *Machine learning dalam bioinformatika*. Malang: UB Press, 2021.
- [16] C. Dewi, F. Y. Bilaut, H. J. Christanto, and G. Dai, "Deep Learning for the Classification of Rice Leaf Diseases Using YOLOv8," *Mathematical Modelling of Engineering Problems*, vol. 11, no. 11, pp. 3025–3034, Nov. 2024, doi: 10.18280/mmep.111115.
- [17] M. Agustin, I. Hermawan, D. Arnaldy, A. T. Muharram, and B. Warsuta, "Design of Livestream Video System and Classification of Rice Disease," *JOIV: International Journal on Informatics Visualization*, vol. 7, no. 1, p. 139, Feb. 2023, doi: 10.30630/joiv.7.1.1336.
- [18] E. Haque, M. Paul, A. Rahman, F. Tohidi, and J. Islam, "Rice Leaf Disease Detection and Classification Using Shallow Trained YOLOv7 Active Deep Learning Approach," in *2023 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, IEEE, Nov. 2023, pp. 516–522. doi: 10.1109/DICTA60407.2023.00077.
- [19] M. E. Haque, A. Rahman, I. Junaaid, S. U. Hoque, and M. Paul, "Rice Leaf Disease Classification and Detection Using YOLOv5," Sep. 2022, doi: 10.48550/arxiv.2209.01579.
- [20] K. A. Baihaqi and Y. Cahyana, "Application of Convolution Neural Network Algorithm for Rice Type Detection Using Yolo v3," *Systematics*, vol. 3, no. 2, pp. 272–280, 2021.
- [21] R. Kashyap, J. G. Kotwal, and P. Mohd. Shafi, "Yolov5-based Convolutional Feature Attention Neural Network for Plant Disease Classification," *International Journal of Intelligent Systems Technologies and Applications*, vol. 22, no. 3, 2024, doi: 10.1504/IJISTA.2024.10062157.
- [22] F. Khan, N. Zafar, M. N. Tahir, M. Aqib, H. Waheed, and Z. Haroon, "A mobile-based system for maize plant leaf disease detection and classification using deep learning," *Front Plant Sci*, vol. 14, May 2023, doi: 10.3389/fpls.2023.1079366.