

EVALUASI AUGMENTASI DATA PADA DETEKSI PENYAKIT DAUN TEBU DENGAN YOLOV8

Ibnu Topan Adib Amrulloh, Betha Nurina Sari, Tesa Nur Padilah

Informatika, Universitas Singaperbangsa Karawang, Jl. HS.Ronggo Waluyo, Puseurjaya, Kec. Telukjambe Timur, Kabupaten Karawang, Jawa Barat
2010631170078@student.unsika.ac.id

ABSTRAK

Tebu merupakan tanaman dari keluarga rumput-rumputan yang sangat terkenal di seluruh dunia karena perannya dalam menghasilkan gula dan etanol. Mengingat peran penting tebu, peningkatan produktivitas dan efisiensi pengelolaan tanaman menjadi sangat penting. Salah satu aspek yang memerlukan perhatian adalah masalah kesehatan tanaman tebu, yang dapat berdampak pada hasil panen dan kualitas tebu. Deteksi dini dan penanganan tepat menjadi kunci untuk mengambil tindakan pencegahan yang tepat. Penggunaan model deteksi objek seperti YOLOv8, yang menunjukkan performa superior dalam deteksi objek dengan kecepatan dan akurasi tinggi, menjadi solusi menjanjikan. Namun, tantangan utama dalam penggunaan YOLOv8 adalah kebutuhan data besar dan beragam untuk pelatihan. Teknik data augmentasi membantu mengatasi tantangan ini dengan memperluas dan memperkaya dataset melalui variasi data seperti *horizontal flipping*, *jittering scale* dan *random brightness*. Hasil penelitian menunjukkan bahwa penggunaan data augmentasi secara signifikan meningkatkan kinerja YOLOv8 dalam mendeteksi penyakit daun tebu, dengan peningkatan nilai mAP dari 40.3% menjadi 50.5%. Data augmentasi membantu model mengatasi *overfitting* dan meningkatkan kemampuan generalisasi. Penelitian ini memberikan kontribusi signifikan dalam bidang pertanian presisi, membantu petani mendeteksi penyakit secara lebih dini dan efektif, meningkatkan hasil panen, serta mengurangi kerugian akibat penyakit tanaman.

Kata kunci : tebu, penyakit daun, deteksi dini, YOLOv8, data augmentasi

1. PENDAHULUAN

Tebu merupakan tanaman dari keluarga rumput-rumputan yang sangat terkenal di seluruh dunia karena perannya dalam menghasilkan gula dan etanol. Tanaman ini menghasilkan gula yang digunakan dalam makanan, serta etanol anhidrat yang merupakan bahan bakar tambahan untuk bensin, dan etanol hidrat yang digunakan untuk kendaraan fleksibel [1].

Namun, produktivitas tanaman tebu sering kali terancam oleh berbagai penyakit yang dapat mengurangi hasil panen secara signifikan. Deteksi dini dan penanganan yang tepat terhadap penyakit ini sangat penting untuk menjaga stabilitas produksi. Untuk mengatasi masalah tersebut, deteksi penyakit pada daun tanaman tebu sangat penting [2]. Hal ini disebabkan oleh peran penting daun dalam proses fotosintesis tanaman tebu. Sebagai proses penting dalam menghasilkan energi bagi tanaman, fotosintesis sangat bergantung pada kesehatan dan fungsi optimal daun.

Serangan penyakit seperti karat daun, mosaik, dan penyakit *redrot* dapat memengaruhi produktivitas tanaman tebu [3][4]. Oleh karena itu, mengidentifikasi gejala penyakit pada daun sejak dini sangat penting untuk mencegah dan menanggulangi masalah ini. Petani dapat mengambil tindakan yang tepat dengan mendeteksi penyakit sejak dini, seperti menerapkan strategi pengendalian penyakit atau memilih varietas tanaman yang lebih tahan terhadap penyakit.

Para ahli biasanya menggunakan pengamatan secara kasat mata untuk mengidentifikasi dan mendeteksi penyakit daun tebu, yang biasanya

mebutuhkan pengamatan terus menerus untuk memastikan dan memvalidasi diagnosis [5]. Dalam menghadapi masalah ini, perkembangan terbaru dalam sistem otomatis untuk deteksi dini penyakit pada daun tanaman tebu memberikan solusi efisien dan praktis. Salah satu teknologi yang menjanjikan dalam deteksi penyakit pada tanaman adalah penggunaan model deteksi objek seperti *You Only Look Once* (YOLO). YOLOv8, versi terbaru dari keluarga model YOLO, telah menunjukkan performa yang superior dalam tugas deteksi objek dengan kecepatan dan akurasi yang lebih baik dibandingkan versi sebelumnya [6]. Model ini mampu mendeteksi dan mengklasifikasikan objek dalam gambar dengan cepat, menjadikannya alat yang ideal untuk aplikasi pertanian seperti deteksi penyakit tanaman.

Namun, salah satu tantangan dalam menggunakan model YOLOv8 adalah kebutuhan akan jumlah data yang besar dan beragam untuk melatih model agar mampu mengenali berbagai jenis penyakit dengan akurasi tinggi [7]. Di sinilah data augmentasi memainkan peranan penting. Data augmentasi adalah teknik yang digunakan untuk memperluas dan memperkaya dataset dengan menghasilkan variasi dari data yang ada, seperti melalui rotasi, flipping, zooming, perubahan pencahayaan, dan lain-lain. Teknik ini tidak hanya meningkatkan jumlah data pelatihan tetapi juga membantu model untuk menjadi lebih robust terhadap berbagai kondisi lingkungan yang berbeda [8].

Penelitian ini bertujuan untuk mengeksplorasi pengaruh data augmentasi terhadap performa

YOLOv8 dalam mendeteksi penyakit pada tanaman tebu. Dengan memahami bagaimana berbagai teknik augmentasi dapat meningkatkan kemampuan model dalam mengenali penyakit, diharapkan dapat diperoleh model deteksi yang lebih akurat dan andal. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang pertanian presisi, membantu petani untuk mendeteksi penyakit secara lebih dini dan efektif, sehingga meningkatkan hasil panen dan mengurangi kerugian akibat penyakit tanaman.

2. TINJAUAN PUSTAKA

Penelitian pertama yang berjudul "Disease Recognition in Sugarcane Crop Using Deep Learning" menunjukkan bahwa YOLO dapat digunakan untuk menentukan lokalitas daerah yang terinfeksi penyakit pada tanaman tebu dengan skor mean average precision (mAP) tertinggi sebesar 58,13%. Hal ini menunjukkan bahwa meskipun YOLO memiliki kemampuan yang baik dalam mendeteksi penyakit, ada ruang untuk perbaikan, terutama dalam hal akurasi lokalitas [9].

Penelitian kedua berjudul "Sugar Cane Red Stripe Disease Detection using YOLO CNN of Deep Learning Technique" memperkuat keandalan YOLO dalam mendeteksi penyakit pada daun tebu. Hasil penelitian ini menunjukkan bahwa YOLO mampu mencapai akurasi rata-rata sebesar 95,90% dan 91,30% dengan akurasi tertinggi mencapai 98,45% dan 97,26%. Kecepatan deteksi yang cepat dengan durasi rata-rata estimasi sekitar 1,46 detik hingga 1,53 detik membuat YOLO sangat berguna untuk aplikasi di lapangan [10].


Penelitian yang berjudul "Evaluating Data Augmentation Effects on the Recognition of Sugarcane Leaf Spot" menunjukkan pengaruh positif augmentasi data terhadap akurasi model dalam mendeteksi penyakit pada tanaman tebu. Dalam penelitian ini, penggunaan metode augmentasi seperti supervised augmentation dan DCGAN berhasil meningkatkan akurasi model MobileNetV3-large dari 53,5% menjadi 99% setelah menghapus latar belakang dan menambahkan gambar sintetis dari DCGAN. Hal ini menunjukkan bahwa augmentasi data tidak hanya meningkatkan jumlah data pelatihan tetapi juga memperkenalkan variasi yang membantu model mengenali pola yang lebih kompleks [11].

Penelitian lain yang berjudul "Simple Training Strategies and Model Scaling for Object Detection" menyoroti pentingnya strategi augmentasi yang kuat seperti horizontal flipping dan jittering scale dalam meningkatkan performa algoritma deteksi objek seperti RetinaNet dan RCNN. Penelitian ini menunjukkan bahwa penggunaan jittering scale yang besar dapat meningkatkan Average Precision (AP) dari 35,7% menjadi 47,9% selama 600 epoch. Ini menunjukkan bahwa augmentasi skala jittering yang tepat dapat membantu model menjadi lebih tangguh dan mampu mengenali objek pada berbagai skala [12].

Berdasarkan hasil penelitian sebelumnya, YOLO telah terbukti cukup akurat dan cepat dalam mendeteksi penyakit pada daun tebu. Namun, hasil deteksi YOLO dapat ditingkatkan lebih lanjut dengan menggunakan teknik augmentasi data yang tepat. Augmentasi data tidak hanya membantu dalam memperluas dataset dengan variasi gambar yang lebih banyak tetapi juga meningkatkan ketahanan model terhadap variasi dan kompleksitas yang ditemukan dalam skenario nyata. Dengan demikian, penerapan data augmentasi dalam pelatihan model YOLO dapat memberikan performa deteksi yang lebih baik dan lebih akurat dalam mendeteksi penyakit pada daun tebu.

3. METODE PENELITIAN

Diagram *workflow* pada Gambar 1. menunjukkan tahap – tahap untuk mengetahui apakah augmentasi data dapat mempengaruhi performa YOLO dalam mendeteksi penyakit pada daun tanaman tebu. Tahapan-tahapan yang berbeda dalam pemrosesan adalah sebagai berikut:



Gambar 1. Diagram *workflow* evaluasi augmentasi data pada deteksi penyakit daun tebu dengan YOLO


3.1. Pengumpulan Data

Dataset dikumpulkan dari sumber website data.mendeley.com. Dataset ini berisi 2521 gambar daun tebu yang termasuk dalam lima kelas (terdiri dari empat penyakit dan satu sehat). Keempat jenis penyakit tersebut adalah Mosaik, *Rust* (Karat Daun), *Redrot*, dan *Yellow Leaf Disease*. Namun, karena keterbatasan sumber daya yang tersedia untuk komputasi gambar, penyakit *Yellow Leaf Disease* tidak dimasukkan dalam penelitian ini. Oleh karena itu, total data yang digunakan dalam penelitian ini berjumlah 2016 gambar daun tebu, yang terbagi ke dalam empat kelas utama: *Healthy* (Sehat), *Rust* (Karat Daun),

Mosaik, dan *Redrot*. Distribusi gambar untuk setiap kelas dapat dilihat pada Tabel 1. Gambar 2. menunjukkan contoh gambar daun dari dataset yang mewakili setiap kelas.

Tabel 1 Distribusi gambar pada setiap kelas


No	Nama Kelas	Jumlah Gambar
1	<i>Healthy</i> (Daun Sehat)	522
2	<i>Rust</i> (Karat Daun)	514
3	Mosaik	462
4	<i>Redrot</i>	585



Gambar 2. Gambar daun tebu pada dataset (1) daun sehat, (2) penyakit mosaik, (3) penyakit *redrot* (4) penyakit karat daun

3.2. Penghapusan Duplikasi Data

Beberapa gambar dalam dataset terlihat identik. Untuk memastikan gambar-gambar ini benar-benar duplikat, perlu dilakukan verifikasi lebih lanjut dengan metode *hashing*. Proses ini mengubah setiap gambar menjadi *hash*, yang kemudian dibandingkan satu sama lain. *Hashing* mengubah data menjadi nilai *hash* dengan panjang tetap. Dua set data yang sama akan menghasilkan *hash* yang sama. Algoritma *hash* MD5 digunakan dalam proses ini, mengubah data menjadi nilai *hash* 128-bit dalam format 32 karakter heksadesimal [13]. Jika dua gambar memiliki *hash* MD5 yang sama, gambar tersebut kemungkinan besar duplikat. Pendekatan ini efektif untuk menemukan gambar duplikat dalam dataset. Gambar 3. menunjukkan jumlah gambar yang duplikat



Gambar 3. Jumlah gambar duplikat pada masing-masing kelas

Duplikasi gambar paling banyak terjadi pada kelas mosaik dan *rust* (karat daun), sementara kelas

redrot tidak memiliki duplikasi gambar. Setelah semua gambar duplikat ditemukan, gambar-gambar tersebut akan dihapus. Setelah semua gambar duplikat dihapus jumlah gambar pada dataset tersisa sebanyak 1793 gambar yang terbagi dalam empat kelas. Distribusi gambar pada setiap kelas setelah penghapusan gambar duplikat dapat dilihat pada tabel 2.

Tabel 2. Distribusi kelas setelah gambar duplikat dihapus

No	Nama Kelas	Jumlah Gambar
1	<i>Healthy</i> (Daun Sehat)	476
2	<i>Rust</i> (Karat Daun)	376
3	Mosaik	518
4	<i>Redrot</i>	447


3.3. Pelabelan dan Pembagian Dataset

Setelah semua gambar duplikat dihapus langkah selanjutnya adalah melakukan pelabelan dan pembagian dataset. Pelabelan dilakukan dengan cara memberikan anotasi pada setiap gambar. Anotasi ini berbentuk *bounding box* yang mengelilingi bagian daun tebu yang terkena penyakit. Setiap anotasi dilengkapi dengan label yang sesuai dengan kategori penyakitnya, seperti mosaik, *red rot*, dan *rust* pada Selain itu, anotasi juga ditambahkan pada gambar daun tebu yang sehat untuk memungkinkan model membedakan antara daun tebu yang sehat dan yang terkena penyakit. Sampel dari dataset dapat dilihat pada gambar 4.



Gambar 4. Sampel dari dataset

Setelah semua gambar dianotasi, dataset dibagi dengan rasio 80:20, dimana 80% gambar digunakan sebagai data latih (*train*) dan 20% sebagai data uji (*test*). Data latih digunakan untuk melatih model YOLO dan data uji digunakan untuk menguji performa YOLO. Gambar 5. Menunjukkan menunjukkan jumlah objek pada setiap kelas, objek ini adalah bagian daun yang terkena penyakit ataupun yang sehat.



Gambar 5 Jumlah Objek pada Dataset

3.4. Data Augmentasi

Penelitian ini menerapkan teknik augmentasi data yang serupa dengan yang digunakan oleh [12], yaitu *flipping horizontal* dan *jittering scale* dengan skala [0.75, 1.5]. Selain itu, penelitian ini menggunakan teknik augmentasi tambahan, yaitu *random brightness*, untuk lebih memperkaya variasi data.

Teknik *horizontal flipping* membalik gambar secara horizontal, sehingga objek yang ada di sebelah kanan gambar akan berpindah ke sebelah kiri, dan sebaliknya, menciptakan variasi dalam orientasi objek tanpa mengubah konten gambar. Teknik *jittering scale* mengubah ukuran objek dalam gambar dengan skala acak antara [0.75, 1.0], memperbesar atau memperkecil objek dalam gambar, yang membantu model belajar mengenali objek dalam berbagai ukuran dan skala. Teknik *random brightness* mengubah kecerahan gambar secara acak dalam rentang -0.15 hingga 0.15, menambahkan variasi dalam intensitas cahaya pada gambar, yang membantu model belajar mengenali objek dalam kondisi pencahayaan yang berbeda.

Setiap teknik augmentasi yang diterapkan akan menyebabkan perubahan pada posisi dan bentuk objek dalam gambar, sehingga *bounding box* yang digunakan untuk mendefinisikan lokasi dan ukuran objek dalam gambar juga harus diubah sesuai dengan perubahan yang terjadi.

Penelitian ini menguji performa model pada dua set data yang berbeda yaitu data yang telah mengalami augmentasi dan data yang tidak mengalami augmentasi. Pada set data pertama, gambar-gambar akan diaugmentasi menggunakan teknik-teknik yang telah dijelaskan sebelumnya, seperti *horizontal flipping*, *jittering scale*, dan *random brightness*. Pada set data kedua, gambar-gambar akan digunakan dalam bentuk aslinya tanpa augmentasi.

3.5. Pembuatan dan Pelatihan Model

Model yang digunakan dalam penelitian ini adalah YOLOv8 dengan *backbone "s"* (*small*), yang memanfaatkan bobot yang telah dilatih sebelumnya pada dataset COCO. *Backbone "s"* pada YOLOv8 merujuk pada versi kecil dari jaringan backbone yang digunakan untuk ekstraksi fitur dalam model tersebut.

Backbone "s" merupakan versi ringan dari jaringan backbone YOLOv8. Dibandingkan dengan versi yang lebih besar, seperti *medium*, *large*, atau *extra-large*, *backbone "s"* memiliki lebih sedikit lapisan dan parameter. Tujuan dari penggunaan *backbone "s"* adalah untuk mengurangi ukuran model dan waktu komputasi.

Dengan bobot yang telah dilatih sebelumnya pada dataset COCO, YOLOv8 telah mempelajari fitur-fitur dasar dari jutaan gambar. Hal ini memungkinkan model untuk memberikan representasi fitur yang kuat, yang berguna dalam deteksi penyakit pada daun tebu. Pelatihan YOLOv8 dalam penelitian ini menggunakan parameter-parameter yang tercantum pada Tabel 3.

Tabel 3 Parameter yang digunakan untuk melatih model

No	Parameter	Nilai
1	<i>Classification loss</i>	<i>Binary crossentropy</i>
2	<i>Bounding box loss</i>	CIOU
3	<i>optimizer</i>	Adam
4	<i>Learning rate</i>	2.5×10^{-4}
5	<i>Epoch</i>	50

YOLOv8 dilatih dengan menggunakan gambar dengan resolusi 512 x 512. Model ini dilatih menggunakan data yang sudah dilakukan augmentasi dan tidak dilakukan augmentasi. Dengan melakukan ini, penelitian bertujuan untuk mengevaluasi sejauh mana teknik augmentasi yang diterapkan dapat meningkatkan kemampuan model dalam mengenali dan mengklasifikasikan objek. Model akan dilatih dengan kedua set data ini secara terpisah untuk memahami perbedaan performa yang dihasilkan.

Selain itu, penelitian ini juga menerapkan sebuah *callback* di mana model akan disimpan jika nilai mAP pada iterasi saat ini lebih tinggi dibandingkan dengan iterasi sebelumnya. Hal ini bertujuan untuk memperbaiki model secara otomatis dan meningkatkan kinerjanya seiring dengan proses pelatihan.

3.6. Evaluasi

Untuk mengevaluasi kinerja model YOLOv8, penelitian ini menggunakan metrik *Mean Average Precision* (mAP). Dalam penelitian ini, digunakan *threshold 50%* untuk IOU (*Intersection Over Union*). Dengan menggunakan *threshold 50%*, prediksi dianggap benar jika IOU antara *bounding box* hasil prediksi dan *bounding box ground truth* minimal 50%. *Mean Average Precision* (mAP) mengukur kinerja suatu sistem deteksi objek dengan mempertimbangkan presisi (*precision*) pada berbagai tingkat *recall*. *Recall* merupakan perbandingan antara jumlah objek yang berhasil dideteksi dengan total jumlah objek sebenarnya. Proses perhitungan mAP dimulai dengan menentukan apakah suatu prediksi dianggap benar positif (*true positive*) berdasarkan nilai *Intersection over Union* (IoU) antara prediksi dan label *ground truth*. Jika $\text{IoU} \geq \text{threshold}$, maka prediksi dianggap benar positif. Selanjutnya, untuk setiap kelas, dihitung nilai presisi maksimum (AP_r) pada 11 tingkat *recall* yang berbeda, yaitu 0, 0.1, 0.2, ..., 0.9, dan 1.0. Presisi maksimum pada suatu tingkat *recall* adalah nilai presisi tertinggi untuk *recall* yang lebih besar atau sama dengan tingkat *recall* tersebut. Kemudian, dihitung nilai presisi rata-rata (AP) untuk setiap kelas, yang merupakan rata-rata dari 11 nilai presisi tersebut [14].

$$AP = \frac{1}{11} \sum_{r \in \{0.0, \dots, 1.0\}} AP_r$$

$$= \frac{1}{11} \sum_{r \in \{0.0, \dots, 1.0\}} P_{interp}(r) \quad (1)$$

Dimana

$$P_{interp}(r) = \max_{\tilde{r} \geq r} p(\tilde{r}) \quad (2)$$


mAP sendiri dihitung sebagai rata-rata dari nilai-nilai AP untuk semua kelas yang ada.

4. HASIL DAN PEMBAHASAN


Setelah model YOLOV8 dilatih menggunakan data dengan augmentasi dan tanpa augmentasi selama 50 epoch, model dievaluasi menggunakan metrik Mean Average Precision (mAP). Berikut adalah hasil dari pelatihan model.

4.1. Kinerja Model pada Data Tanpa Augmentasi

Setelah model YOLOV8 dilatih menggunakan gambar dengan resolusi 512 x 512 tanpa augmentasi selama 50 epoch, hasil evaluasi menunjukkan bahwa model tersebut mencapai nilai *Mean Average Precision* (mAP) tertinggi sebesar 40.3%. Proses pelatihan ini menggunakan data asli tanpa adanya teknik augmentasi. Gambar 6. menunjukkan *loss* yang didapat saat model dilatih tanpa menggunakan teknik augmentasi. Gambar 7. Menunjukkan perubahan nilai MAP pada setiap epoch




Gambar 6 Training loss(oranye) dan validation loss(biru) model YOLOV8 pada data yang tidak diaugmentasi untuk setiap epochs




Gambar 7. Mean Average Precision (mAP) model YOLOV8 pada data yang tidak diaugmentasi untuk setiap epochs

4.2. Kinerja Model pada Data dengan Augmentasi

Setelah model YOLOV8 dilatih dengan menggunakan data yang sudah diterapkan teknik augmentasi *horizontal flipping*, *jittering scale* dan *random brightness* pada gambar dengan resolusi 512 x 512 selama 50 epoch, hasil evaluasi menunjukkan bahwa model tersebut mencapai nilai Mean Average Precision (mAP) tertinggi sebesar 50.5%. Gambar 8. menunjukkan *loss* yang didapat saat model dilatih tanpa menggunakan teknik augmentasi. Gambar 9. Menunjukkan perubahan nilai MAP pada setiap epoch



Gambar 8. Training loss(oranye) dan validation loss(biru) model YOLOV8 pada data yang di augmentasi untuk setiap epochs



Gambar 9 Mean Average Precision (mAP) model YOLOV8 pada data yang sudah di augmentasi untuk setiap epochs

4.3. Analisis Perbandingan

Perbandingan antara kinerja model pada data tanpa augmentasi dan data dengan augmentasi menunjukkan bahwa data augmentasi memiliki dampak positif yang signifikan terhadap kemampuan deteksi penyakit pada daun tebu. Teknik augmentasi yang digunakan, seperti *horizontal flipping*, *jittering scale*, dan *random brightness*, membantu meningkatkan variasi pada data pelatihan. Ini memungkinkan model untuk mempelajari pola yang lebih beragam, sehingga meningkatkan kemampuan model untuk mengenali variasi pada data uji.

Peningkatan nilai mAP dari 40.3% menjadi 50.5% menunjukkan bahwa model yang dilatih dengan data augmentasi memiliki kemampuan yang lebih baik

dalam mendeteksi penyakit pada daun tebu. Selain itu, grafik loss yang lebih stabil dan konsisten pada pelatihan dengan data augmentasi menunjukkan bahwa model tidak mengalami overfitting, sehingga lebih mampu menggeneralisasi pada data uji.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa penggunaan teknik data augmentasi pada pelatihan model YOLOv8 secara signifikan meningkatkan kinerja model dalam mendeteksi penyakit pada daun tebu, dengan peningkatan nilai mAP dari 40.3% menjadi 50.5%. Data augmentasi membantu model mengatasi overfitting dan meningkatkan kemampuan generalisasi, membuatnya lebih andal dalam mengenali variasi pada data uji. Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi lebih banyak teknik augmentasi. Selain itu penelitian berikutnya juga bisa menggunakan dataset dengan jumlah data yang lebih banyak.

DAFTAR PUSTAKA

- [1] H. dan P. Direktorat Statistik Tanaman Pangan, *STATISTIK TEBU INDONESIA*, vol. 13. ©BPS RI/BPS – Statistics Indonesia, 2023.
- [2] R. Hariyanto and K. Sa'diyah, "Sistem Pakar Diagnosis Penyakit dan Hama Pada Tanaman Tebu Menggunakan Metode Certainty Factor," *JOINTECS (Journal of Information Technology and Computer Science)*, vol. 3, no. 1, pp. 29–32, 2018.
- [3] G. James and B. Tate, *Sugarcane*. Wiley Online Library, 2004.
- [4] D. Zhao, N. C. Glynn, B. Glaz, J. C. Comstock, and S. Sood, "Orange rust effects on leaf photosynthesis and related characters of sugarcane," *Plant Dis*, vol. 95, no. 6, pp. 640–647, 2011.
- [5] S. V. Militante and B. D. Gerardo, "Detecting sugarcane diseases through adaptive deep learning models of convolutional neural network," in *2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*, IEEE, 2019, pp. 1–5.
- [6] M. Hussain, "YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection," *Machines*, vol. 11, no. 7, p. 677, 2023.
- [7] Z. Zou, K. Chen, Z. Shi, Y. Guo, and J. Ye, "Object detection in 20 years: A survey," *Proceedings of the IEEE*, vol. 111, no. 3, pp. 257–276, 2023.
- [8] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J Big Data*, vol. 6, no. 1, pp. 1–48, 2019.
- [9] M. and O. S. N. and J. T. and B. A. and P. M. R. and C. A. Malik Hashmat Shadab and Dwivedi, "Disease Recognition in Sugarcane Crop Using Deep Learning," in *Advances in Artificial Intelligence and Data Engineering*, T. Chiplunkar Niranjana N. and Fukao, Ed., Singapore: Springer Nature Singapore, 2021, pp. 189–206.
- [10] I. Kumpala, N. Wichapha, and P. Prasomsab, "Sugar Cane Red Stripe Disease Detection using YOLO CNN of Deep Learning Technique," *Engineering Access*, vol. 8, no. 2, pp. 192–197, 2022.
- [11] Y. Huang, R. Li, X. Wei, Z. Wang, T. Ge, and X. Qiao, "Evaluating data augmentation effects on the recognition of sugarcane leaf spot," *Agriculture*, vol. 12, no. 12, p. 1997, 2022.
- [12] X. Du, B. Zoph, W.-C. Hung, and T.-Y. Lin, "Simple training strategies and model scaling for object detection," *arXiv preprint arXiv:2107.00057*, 2021.
- [13] I. Rahim, N. Anwar, A. M. Widodo, K. K. Juman, and I. Setiawan, "Komparasi Fungsi Hash Md5 Dan Sha256 Dalam Keamanan Gambar Dan Teks," *IKRA-ITH Informatika: Jurnal Komputer dan Informatika*, vol. 7, no. 2, 2023.
- [14] S. M. Beitzel, E. C. Jensen, and O. Frieder, "Map," *Encyclopedia of Database Systems*, pp. 1691–1692, 2009.