

RESEARCH ARTICLE

Implementasi Model *Deep Learning* Pada Sistem Deteksi dan Klasifikasi Kualitas Batang Tebu untuk Optimalisasi Penentuan Kualitas

Anggiat Pandu Daniel Siregar, Nur Ichsan Utama* and Riska Yanu Fa'rifah

Fakultas Rekayasa Industri, Universitas Telkom, Bandung, 40257, Jawa Barat, Indonesia

*Corresponding author: nichsan@telkomuniversity.ac.id

Abstrak

Industri gula nasional mengalami penurunan produksi sebesar 7,01% pada tahun 2023, salah satunya disebabkan oleh rendahnya efisiensi pascapanen akibat proses klasifikasi mutu batang tebu yang masih dilakukan secara manual. Proses ini menimbulkan inkonsistensi, potensi konflik antara petani dan petugas lapangan, serta peningkatan biaya operasional. Penelitian ini mengembangkan sistem klasifikasi mutu batang tebu berbasis *deep learning* menggunakan pendekatan dua tahap. Tahap pertama menggunakan YOLOv11 untuk mendeteksi batang tebu, sedangkan tahap kedua menggunakan arsitektur *EfficientNet* (B0-B3) untuk mengklasifikasikan mutu ke dalam lima kategori (A-E). Dataset citra diperoleh dari jalur produksi PT Sinergi Gula Nusantara dan diproses melalui tahapan *Knowledge Discovery in Database* (KDD), meliputi data *preprocessing*, *augmentasi*, *resizing*, dan *splitting*. Hasil evaluasi menunjukkan bahwa YOLOv11 mencapai akurasi 93,5%, *precision* 95,7%, *recall* 94,4%, *mAP@0.5* sebesar 97,8%, dan *mAP@0.5:0.95* sebesar 89,4%. Sementara itu, *EfficientNet*-B2 menghasilkan akurasi klasifikasi tertinggi sebesar 88,57% setelah proses *fine-tuning*. Sistem yang dikembangkan mampu beroperasi pada kondisi visual yang kompleks dan dinamis, serta memberikan hasil klasifikasi yang konsisten. Studi ini menunjukkan potensi teknologi *deep learning* dalam mendukung otomatisasi dan peningkatan objektivitas proses penilaian mutu di industri agroindustri.

Key words: *Deep Learning*, *EfficientNet*, KDD, Klasifikasi Kualitas Batang Tebu, YOLOv11

Pendahuluan

Industri pertanian memegang peranan penting dalam perekonomian Indonesia, dengan tebu (*Saccharum officinarum* L.) menjadi salah satu komoditas utama yang mendukung produksi gula nasional. Gula tidak hanya menjadi kebutuhan pokok masyarakat, tetapi juga merupakan bahan baku utama bagi berbagai sektor industri, termasuk makanan dan minuman [1]. Berdasarkan data Badan Pusat Statistik (BPS), produksi gula nasional pada tahun 2023 mencapai 2,23 juta ton, meskipun angka tersebut mengalami penurunan sebesar 7,01% dibandingkan tahun sebelumnya. Salah satu faktor yang memengaruhi penurunan produksi gula adalah kualitas batang tebu, mengingat rendemen gula sangat bergantung pada mutu batang yang digunakan dalam proses ekstraksi [2]. Perusahaan dalam industri gula, khususnya yang berada di wilayah Jawa Timur, yang menyumbang sekitar 49% dari total produksi gula nasional menghadapi tantangan dalam menjaga konsistensi kualitas produk. Proses identifikasi dan klasifikasi batang tebu umumnya masih dilakukan secara manual oleh tenaga kerja manusia, yang mengakibatkan ketidakkonsistenan penilaian, peningkatan risiko kesalahan manusia (*human error*), serta perlambatan proses produksi. Kualitas batang tebu biasanya diklasifikasikan ke dalam lima kategori berdasarkan karakteristik visual, yaitu A (prima), B (matang, bersih, segar), C (kotor), D (sangat kotor), dan E (terbakar). Kriteria

visual tersebut mencakup kebersihan, tingkat kematangan, dan cacat fisik, di mana kategori A menggambarkan batang yang bersih dan lurus, sementara kategori E menunjukkan batang yang terbakar atau mengalami kerusakan parah [3].

Seiring dengan kemajuan teknologi *artificial intelligence* (AI), pendekatan *deep learning* telah terbukti efektif dalam berbagai studi untuk menyelesaikan permasalahan deteksi dan klasifikasi objek [4][5]. Dalam penelitian ini, metode *you only look once* version 11 (YOLOv11) digunakan untuk mendeteksi batang tebu secara *real-time*, sementara *EfficientNet* digunakan untuk mengklasifikasikan kualitas batang tebu ke dalam lima kategori yang telah disebutkan sebelumnya. YOLOv11 dikenal karena kemampuannya dalam mendeteksi objek dengan cepat dan akurat [6][7]. Sedangkan, *EfficientNet* menawarkan efisiensi komputasi tinggi melalui pendekatan *compound scaling* yang menyeimbangkan kedalaman (*depth*), lebar (*width*), dan resolusi dari jaringan saraf (*neural network*) [8]. Penelitian ini relevan dengan beberapa studi sebelumnya. Hasan dkk. (2023) melakukan penelitian mengenai deteksi dan klasifikasi penyakit pada daun kopi menggunakan YOLOv7, dengan hasil performa tinggi berupa nilai *F1-score* sebesar 0,93 dan *mAP@IoU0.5* sebesar 0,956. Penelitian tersebut menggunakan pendekatan dua tahap, yaitu deteksi objek daun kopi, diikuti dengan klasifikasi penyakit. Perbedaan mendasar dari penelitian ini terletak pada objek dan fokus klasifikasinya, di mana penelitian Hasan


Selain itu, penelitian oleh Yepes dkk. (2022) menunjukkan potensi metode *supervised machine learning* dalam memprediksi hasil panen tebu berdasarkan sifat kesuburan tanah, yang menegaskan relevansi penerapan solusi berbasis AI dalam sektor pertanian, khususnya untuk meningkatkan pengambilan keputusan dan efisiensi operasional dalam produksi tebu [10]. Penelitian lainnya oleh Kunderacioglu & Pacal (2024) menggunakan pendekatan *deep learning*, termasuk *EfficientNet* dan *InceptionV4*, untuk mendeteksi penyakit pada daun tebu, dengan akurasi tertinggi mencapai 93,39%. Fokus utama penelitian tersebut adalah membantu petani dalam mengenali penyakit tanaman. Sebaliknya, penelitian ini bertujuan untuk mengoptimalkan proses produksi gula melalui klasifikasi kualitas batang tebu, bukan sekadar mendeteksi penyakit tanaman [?].

Selain permasalahan teknis, proses klasifikasi batang tebu secara manual juga menimbulkan permasalahan kepercayaan (*trust issue*) antara petani dan pihak pabrik. Ketidakkonsistenan dalam penilaian mutu seringkali memicu ketidakpuasan, yang pada akhirnya dapat memengaruhi hubungan bisnis dan keberlanjutan kemitraan antara kedua pihak. Di sisi lain, ketergantungan pada tenaga kerja manusia dalam proses klasifikasi juga berdampak pada tingginya biaya operasional (*operational cost*), terutama dalam skala produksi besar yang membutuhkan kecepatan dan ketepatan dalam penanganan bahan baku. Dengan mempertimbangkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem otomatis berbasis YOLOv11 dan *EfficientNet* yang dapat membantu perusahaan dalam industri gula untuk meningkatkan efisiensi identifikasi batang tebu dan menjaga konsistensi mutu gula yang dihasilkan. Kombinasi dari kedua algoritma *deep learning* ini diharapkan mampu menjadi solusi teknologi yang efektif bagi industri pertanian, khususnya dalam proses pengolahan tebu [11].

Klasifikasi Kualitas Batang Tebu

Klasifikasi kualitas tebu merupakan tahapan penting dalam rantai pasok industri gula, karena secara langsung memengaruhi yield atau rendemen gula serta efisiensi proses produksi. Mutu tebu yang baik akan menghasilkan rendemen tinggi dan mengurangi limbah proses ekstraksi. Umumnya, pabrik gula di Indonesia menggunakan metode klasifikasi manual berbasis visual untuk menilai kebersihan, tingkat kematangan, dan kondisi fisik batang tebu [3]. Pabrik-pabrik seperti Gempolkrep, Tjoekir, dan Mojopanggung, misalnya, menggunakan lima tingkatan mutu: A (prima), B (masak bersih segar), C (kotor), D (sangat kotor), dan E (terbakar).

Labeling atau anotasi merupakan tahap *fundamental* dalam pengembangan sistem *computer vision* berbasis *artificial intelligence* (AI). Proses ini menyediakan *ground truth* berupa informasi posisi dan kategori objek dalam citra, yang digunakan untuk melatih model *deep learning* agar dapat mengenali pola visual secara akurat [12]. Dalam praktiknya, *platform modern* seperti *Roboflow* dan *Makesense.ai* telah banyak digunakan untuk mempercepat dan mempermudah proses *annotation* baik secara manual maupun semi-otomatis [13]. Kualitas anotasi secara langsung memengaruhi performa akhir model deteksi maupun klasifikasi objek.




Gambar 1. A

Data augmentation merupakan teknik untuk memperluas jumlah dan keragaman data pelatihan dengan memodifikasi citra asli, seperti melalui rotasi, pencahayaan ulang, perubahan kontras, atau penambahan noise. Teknik ini sangat penting dalam menangani dataset terbatas dan mengurangi risiko overfitting, terutama saat mendeteksi objek kecil atau langka [14][15]. Selain memperkaya variasi visual, augmentasi juga meningkatkan *generalization capability model* terhadap kondisi dunia nyata, seperti pencahayaan rendah atau latar yang kompleks [16].

Deep learning merupakan cabang dari machine learning yang menggunakan arsitektur jaringan saraf dalam (deep neural networks) untuk mengenali pola kompleks dalam data visual. Dalam bidang *computer vision*, *deep convolutional neural networks* (CNN) telah terbukti efektif untuk tugas deteksi dan klasifikasi objek [17]. Pengembangan model yang andal memerlukan kombinasi dari arsitektur yang tepat, data representatif, serta strategi pelatihan seperti *hyperparameter tuning*, *data augmentation*, dan *transfer learning* [18][19].

Object detection merupakan bidang penting dalam *computer vision* yang bertujuan mengidentifikasi serta menentukan lokasi objek dalam sebuah citra atau video secara otomatis menggunakan *bounding box*. Algoritma *you only look once* (YOLO) dikenal luas karena kemampuannya dalam melakukan deteksi objek secara cepat dan akurat dalam satu kali proses pemindaian gambar. Versi terbarunya, YOLOv11, memperkenalkan peningkatan signifikan melalui penggunaan arsitektur C3K2 pada bagian *backbone*, modul *channel* and *spatial attention* (C2PSA) pada bagian *neck*, serta pendekatan *anchor-free* pada bagian *head*, yang secara kolektif meningkatkan akurasi deteksi terutama untuk objek kecil dan kompleks [20][7]. Model ini juga mengadopsi fungsi kerugian gabungan seperti *distributed focal loss*, regresi *bounding box*, dan *class probability loss* untuk meningkatkan presisi dan stabilitas prediksi [6][21]. Dengan kecepatan inferensi mencapai 290 FPS dan akurasi tinggi, YOLOv11 menjadi solusi andal untuk berbagai aplikasi industri seperti pertanian, pengawasan, dan transportasi [9].

Object classification adalah proses otomatis untuk mengelompokkan objek dalam gambar ke dalam kelas-kelas tertentu berdasarkan fitur visual seperti bentuk, warna, dan tekstur. Model *EfficientNet*, menawarkan pendekatan *compound scaling* untuk menyeimbangkan kedalaman, lebar, dan resolusi gambar *input* secara simultan, sehingga menghasilkan efisiensi komputasi tinggi tanpa mengorbankan akurasi [22]. Arsitektur ini mampu melampaui performa model populer lainnya seperti ResNet dan *Inception*, serta terbukti efektif dalam berbagai aplikasi klasifikasi visual, termasuk di sektor pertanian. Selain itu, model ini juga diterapkan dalam sistem *mobile-based agriculture* karena



Gambar 5. E

Table 3. C

Parameter	Nilai
Pretrained Model	yolo11n.pt
Task	detect
Mode	train
Epochs	50
Batch Size	32
Dataset Location	/content/dataset/
Loss Function	Cross Entropy Loss
Optimizer	Adam
Learning Rate	0.001
Visualization Outputs	Training Graph, Confusion Matrix

yang membuatnya efektif dalam mengidentifikasi batang tebu di lingkungan kompleks [13][1]. Konfigurasi pelatihan YOLOv11 ditampilkan pada Tabel 3 (C). Kedua, klasifikasi mutu batang tebu dilakukan menggunakan *EfficientNet* (varian B0 hingga B3) karena metode *compound scaling*-nya yang seimbang dalam hal kedalaman (*depth*), lebar (*width*), dan resolusi, sehingga menghasilkan akurasi tinggi dengan efisiensi komputasi yang baik [?]. Proses pelatihan dilakukan dalam dua tahap, yaitu *pre-fine-tuning* dan *post-fine-tuning*. Pada tahap awal, seluruh lapisan dibekukan kecuali lapisan klasifikasi untuk mengukur performa dasar. Selanjutnya, pada tahap *fine-tuning*, 20 lapisan terakhir diaktifkan agar model lebih mampu mengenali fitur spesifik batang tebu tanpa mengorbankan efisiensi komputasi. Detail konfigurasi pelatihan ditampilkan pada Tabel 4 (D).

Evaluasi/Evaluation

Tahap evaluasi bertujuan untuk mengukur performa model yang dikembangkan guna memastikan kesesuaiannya dengan tujuan penelitian. Untuk tugas deteksi objek menggunakan YOLOv11, evaluasi dilakukan menggunakan metrik *Intersection over Union* (IoU) yang mengukur tingkat tumpang tindih antara *bounding box* prediksi dan *ground truth* [9]. Nilai IoU dihitung dengan rumus persamaan (1) berikut:

$$IoU = \frac{\text{Intersection Area}}{\text{Union Area}} \quad (1)$$

Semakin tinggi nilai IoU, semakin baik akurasi dalam menentukan lokasi objek. Model YOLOv11 dievaluasi dengan dua metrik utama berbasis IoU:

- $mAP@0.5$: *Mean Average Precision* pada ambang IoU 0.5
- $mAP@[0.5 : 0.95]$: Rata-rata AP dari IoU 0.5 hingga 0.95 dengan kenaikan 0.05

Table 4. D

Parameter	Before FineTuning	After FineTuning
Model	<i>EfficientNet</i> (B0, B1, B2, B3 Pretrained)	<i>EfficientNet</i> (B0, B1, B2, B3 Pretrained)
Image Size	B0: 224×224, B1: 240×240, B2: 260×260, B3: 300×300	B0: 224×224, B1: 240×240, B2: 260×260, B3: 300×300
Epochs	50	50
Batch Size	32	32
Frozen Layers	None (all layers trained)	All except last 20 layers
Trained Layers	Default classifier layers	Last 20 layers + modified classifier
Classifier Structure	Single Softmax layer	Linear (512), ReLU, Dropout (0.2), Linear (to output classes)
Loss Function	CrossEntropyLoss	CrossEntropyLoss
Optimizer	Adam (lr = 0.001)	Adam (lr = 0.0001)

Sementara itu, untuk tugas klasifikasi menggunakan *EfficientNet*, evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *f1-score*, serta *confusion matrix* [28]. Rumus evaluasi model klasifikasi sebagai persamaan (2), (3), (4), dan (5) berikut:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

Keterangan:

TP = *True Positive*

TN = *True Negative*

FP = *False Positive*


FN = *False Negative*

Terakhir, *confusion matrix* digunakan untuk memvisualisasikan perbandingan antara label sebenarnya dan prediksi model, yang membantu dalam mengidentifikasi kesalahan klasifikasi serta potensi bias dalam prediksi [29][17]. Ilustrasi *confusion matrix* ditampilkan pada Gambar 6 (F).


Actual Class

Hasil dan Pembahasan

Bagian ini menyajikan hasil evaluasi dari model deteksi objek dan klasifikasi kualitas, serta implikasinya terhadap pemantauan mutu batang tebu dalam lingkungan agroindustri. Penelitian ini mengadopsi kerangka *deep learning* dua tahap, yaitu deteksi objek menggunakan arsitektur YOLOv11 dan klasifikasi mutu menggunakan model *EfficientNet*. Analisis terhadap metrik evaluasi dilakukan secara menyeluruh untuk menilai tingkat keandalan dan efektivitas sistem yang diusulkan.



Gambar 6. F



Gambar 7. H


Table 5. labelformat=empty

Metric	Nilai
Precision	95.7%
Recall	94.4%
mAP@50	97.8%
mAP@50-95	89.4%


Tahap Pertama: Deteksi Objek (YOLOv11)

Pada penelitian ini, tahap pertama pelatihan difokuskan pada proses deteksi objek menggunakan model YOLOv11. Dataset yang digunakan pada tahap ini terdiri dari 6501 citra untuk pelatihan dan 1427 citra untuk validasi. Tujuan utamanya adalah mendeteksi batang tebu secara akurat sebelum dilanjutkan ke tahap klasifikasi kualitas. Proses pelatihan dilakukan menggunakan GPU Tesla T4 dengan memanfaatkan model pralatih YOLOv11n yang terdiri atas 238 lapisan, 2.582.347 parameter, dan kompleksitas komputasi sebesar 6,3 GFLOPs. Model dilatih selama 40 *epoch* dengan batch size sebesar 64 untuk mengoptimalkan nilai *precision*, *recall*, dan *mean average precision* (mAP), serta meminimalkan *loss function*. Kinerja model selama pelatihan divisualisasikan pada Gambar 6 (G), yang menampilkan kurva kerugian dan metrik akurasi. Penurunan yang konsisten pada *box loss*, *classification loss*, dan *distributed focal loss* (DFL loss) menunjukkan proses pembelajaran yang efektif. Sementara itu, peningkatan nilai *precision*, *recall*, dan mAP mencerminkan kemampuan deteksi yang kuat dari model.

Kinerja akhir model, termasuk metrik evaluasi utama seperti *precision*, *recall*, dan *mean average precision* (mAP), dirangkum pada Tabel 5 (E), yang memberikan gambaran komprehensif mengenai efektivitas model deteksi objek dalam mengenali batang tebu. Model YOLOv11 menunjukkan performa yang sangat baik dalam mendeteksi batang tebu, dengan capaian *precision* sebesar 95,7% dan *recall* sebesar 94,4%, yang mengindikasikan jumlah *false positive* dan *false negative* yang rendah. Nilai *mAP@50* sebesar 97,8% serta *mAP@50-95* sebesar 89,4% menegaskan akurasi tinggi model pada berbagai



Gambar 8. I



Gambar 9. J

ambang *Intersection over Union* (IoU), sehingga memastikan deteksi yang andal dalam berbagai kondisi.

Confusion matrix yang ditampilkan pada Gambar 7 (H) memberikan informasi lebih lanjut terkait performa klasifikasi model. Model berhasil mengidentifikasi 679 *instance* batang tebu dengan 21 *false positive* (latar belakang yang salah diklasifikasikan sebagai batang tebu) dan 24 *false negative* (batang tebu yang salah diklasifikasikan sebagai latar belakang). Hasil ini menunjukkan bahwa model memiliki performa deteksi objek yang kuat dengan tingkat kesalahan klasifikasi yang kecil. Setelah tahap evaluasi, model YOLOv11 yang telah dilatih diimplementasikan untuk mendeteksi batang tebu dalam kondisi nyata. Gambar 8 (I) menunjukkan hasil deteksi, di mana model berhasil mengidentifikasi batang tebu dengan *confidence score* sebesar 0,73. Hasil ini membuktikan kemampuan model dalam melakukan deteksi secara efektif pada skenario lapangan.

Tahap Kedua: Klasifikasi Batang Tebu (EfficientNet)

Pada tahap kedua penelitian ini, proses klasifikasi kualitas batang tebu dilakukan menggunakan model *EfficientNetB0*. Tujuan utama dari tahap ini adalah mengelompokkan batang tebu ke dalam kategori mutu yang telah ditentukan berdasarkan fitur citra yang diekstraksi. Dataset yang digunakan terdiri dari 6501 citra pelatihan dan 1427 citra validasi, dengan distribusi kelas yang seimbang. Model dilatih selama 50 *epoch* untuk mencapai performa optimal sekaligus meminimalkan risiko *overfitting*. Evaluasi model dilakukan menggunakan metrik standar, yaitu akurasi, presisi, *recall*, dan F1-score. Proses *fine-tuning* berperan penting dalam meningkatkan kinerja model *pre-trained* dengan menyesuaikan parameter agar lebih sesuai dengan karakteristik dataset spesifik. Dalam penelitian ini, performa klasifikasi dari model *EfficientNet* (B0-B3) dibandingkan antara sebelum dan sesudah proses *fine-tuning* untuk mengetahui sejauh mana peningkatan akurasi dan metrik klasifikasi lainnya.

Table 6. F

Model	Accuracy	Precision	Recall	F1Score
EfficientNetB0	87.14%	0.89	0.85	0.87
EfficientNetB1	86.97%	0.88	0.86	0.87
EfficientNetB2	87.48%	0.87	0.87	0.87
EfficientNetB3	86.72%	0.86	0.85	0.85

Table 7. G

Model	Accuracy	Precision	Recall	F1Score
EfficientNetB0	87.39%	0.88	0.86	0.87
EfficientNetB1	87.90%	0.89	0.86	0.88
EfficientNetB2	88.57%	0.90	0.88	0.89
EfficientNetB3	88.15%	0.89	0.87	0.88


Dataset evaluasi terdiri dari lima kelas mutu (A-E), dan setiap varian *EfficientNet* dilatih menggunakan ukuran *input* yang sesuai. Model diimplementasikan menggunakan *PyTorch* dengan konfigurasi ukuran *input* sebagai berikut: 224×224 piksel untuk *EfficientNet-B0*, 240×240 untuk B1, 260×260 untuk B2, dan 300×300 untuk B3. Hasil awal sebelum dilakukan finetuning digunakan sebagai tolok ukur performa dasar dari masing-masing model. Ringkasan hasil klasifikasi sebelum *fine-tuning* disajikan pada Tabel 6 (F) berikut. Hasil ini menunjukkan bahwa ukuran *input* yang lebih besar tidak selalu menghasilkan akurasi klasifikasi yang lebih baik sebelum dilakukan *fine-tuning*. Namun, setelah proses *fine-tuning*, terjadi peningkatan kinerja klasifikasi pada semua model, sebagaimana ditampilkan pada Tabel 7 (G) berikut.

Model dengan performa terbaik, *EfficientNet-B2*, berhasil mencapai akurasi sebesar 88,57%, disertai peningkatan nilai *precision*, *recall*, dan *F1-score* dibandingkan sebelum proses *fine-tuning*. Hal ini menunjukkan bahwa *fine-tuning* efektif dalam meningkatkan kemampuan generalisasi dan prediktif model. *Confusion matrix* untuk *EfficientNet-B2* pada Gambar 10 (K) memperlihatkan kinerja klasifikasi berdasarkan masing-masing kelas, dengan peningkatan kemampuan model dalam membedakan antar kelas setelah *fine-tuning*. Sementara itu, Gambar 9 (J) menampilkan kurva *loss* dan akurasi selama proses pelatihan dan validasi, yang menunjukkan pola konvergensi yang stabil dan tingkat *overfitting* yang rendah. Temuan ini menegaskan pentingnya proses *fine-tuning* dalam meningkatkan akurasi dan ketahanan model. Penelitian selanjutnya dapat mengeksplorasi teknik augmentasi tambahan serta strategi optimasi hyperparameter untuk lebih meningkatkan performa klasifikasi.

Terakhir, model dikembangkan untuk mengklasifikasikan mutu batang tebu dalam aplikasi dunia nyata, dengan kemampuan yang efektif dalam membedakan setiap tingkat kualitas berdasarkan model klasifikasi yang telah dilatih. Hasil implementasi klasifikasi ditampilkan pada Gambar 11 (L), yang menunjukkan efektivitas model dalam mengidentifikasi dan mengkategorikan mutu batang tebu secara akurat. Penelitian selanjutnya dapat mengeksplorasi penyediaan hyperparameter, teknik augmentasi data tambahan, serta arsitektur *deep learning* alternatif untuk lebih meningkatkan kinerja klasifikasi.

Kesimpulan

Pengembangan aplikasi ini digunakan untuk memudahkan perusahaan tambang dalam pelaporan emisi. Dengan fitur-fiturnya, aplikasi ini meningkatkan efisiensi pelaporan dengan memudahkan perhitungan emisi dengan mengandalkan sensor dan faktor konversi. Oleh karenanya, perhitungan menjadi lebih akurat dengan adanya *input* langsung



Gambar 10. K



Gambar 11. L

dari sensor. Ketersediaan API juga memudahkan pengguna untuk mengambil dan mengolah data sehingga dapat disesuaikan dengan laporan yang dibutuhkan.

Daftar Pustaka

- Kai PM, de Oliveira BM, da Costa RM. Deep Learning-Based Method for Classification of Sugarcane Varieties. *Agronomy*. 2022;12(11):2722.
- Chen W, Ju C, Li Y, Hu S, Qiao X. Sugarcane Stem Node Recognition in Field by Deep Learning Combining Data Expansion. *Applied Sciences*. 2021;11(18):8663.
- Magfiroh IS, Intan KS, Rudi W. Mutu Tebu Industri Gula di Indonesia. In: *Prosiding Seminar Nasional Sosial Ekonomi Fakultas Pertanian*; 2021. .
- Paliwang AAA, Septian MRD, Cahyanti M, Swedia ER. Klasifikasi Penyakit Tanaman Apel Dari Citra Daun Dengan Convolutional Neural Network. *Sebatik*. 2020;24(2):207-12.
- Raschka S, Patterson J, Nolet C. Machine Learning in Python: Main Developments and Technology Trends in Data Science, Machine Learning, and Artificial Intelligence. *Information*. 2020;11(4):193.
- Alif MAR. YOLOv11 for Vehicle Detection: Advancements, Performance, and Applications in Intelligent Transportation Systems. *arXiv preprint arXiv:241022898*. 2024.
- Khanam R, Hussain M. YOLOv11: An Overview of the Key Architectural Enhancements. *arXiv preprint arXiv:241017725*. 2024.
- Cevallos JC, Villagomez JA, Andryshchenko IS. Convolutional Neural Network in the Recognition of Spatial Images of Sugarcane Crops in the Troncal Region of the Coast of Ecuador. In: *Procedia Computer Science*. vol. 150; 2019. p. 757-63.

9. Hasan NF. Deteksi dan Klasifikasi Penyakit Pada Daun Kopi Menggunakan YOLOv7. *Jurnal Sisfokom*. 2023;12(1):30-5.
10. Yepes J, Oré G, Alcântara MS, Hernandez-Figueroa HE, Teruel B. Classification of Sugarcane Yields According to Soil Fertility Properties Using Supervised Machine Learning Methods. *Engenharia Agrícola*. 2022;42(5):e2021023.
11. Pratitis WL, Kurniasari K, Al Fata H. Classification of Spotted Disease on Sugarcane Leaf Image Using Convolutional Neural Network Algorithm. *Jurnal Sistem Telekomunikasi Elektronika Sistem Kontrol Power Sistem dan Komputer*. 2023;3(2):117-28.
12. Khan AA, Laghari AA, Awan SA. Machine Learning in Computer Vision: A Review. *EAI Endorsed Transactions on Scalable Information Systems*. 2021;8(32).
13. Hidayah AN, Radzi SA, Razak NA, Saad WHM, Wong YC, Naja AA. Disease Detection of Solanaceous Crops Using Deep Learning for Robot Vision. *Journal of Robotics and Control*. 2022;3(6):790-9.
14. Kisantal M. Augmentation for Small Object Detection. *arXiv preprint arXiv:190207296*. 2019.
15. Yang Z, Sinnott RO, Bailey J, Ke Q. A Survey of Automated Data Augmentation Algorithms for Deep Learning-Based Image Classification Tasks. *Knowledge and Information Systems*. 2023;65(7):2805-61.
16. Shorten C, Khoshgoftaar TM. A Survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*. 2019;6(1):1-48.
17. Wu X, Sahoo D, Hoi SCH. Recent Advances in Deep Learning for Object Detection. *Neurocomputing*. 2020;396:39-64.
18. Mohammed A, Kora R. A Comprehensive Review on Ensemble Deep Learning: Opportunities and Challenges. *Journal of King Saud University - Computer and Information Sciences*. 2023;35(2):757-74.
19. Wang P, Fan E, Wang P. Comparative Analysis of Image Classification Algorithms Based on Traditional Machine Learning and Deep Learning. *Pattern Recognition Letters*. 2021;141:61-7.
20. He Z, Wang K, Fang T, Su L, Chen R, Fei X. Comprehensive Performance Evaluation of YOLOv11, YOLOv10, YOLOv9, YOLOv8 and YOLOv5 on Object Detection of Power Equipment. *arXiv preprint arXiv:241118871*. 2024.
21. Sivakoti K. Vehicle Detection and Classification for Toll Collection Using YOLOv11 and Ensemble OCR. *arXiv preprint arXiv:241212191*. 2024.
22. Tan M, Le QV. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In: *Proceedings of the International Conference on Machine Learning (ICML)*. PMLR; 2019. p. 6105-14.
23. Daphal SD, Koli SM. Enhanced Deep Learning Technique for Sugarcane Leaf Disease Classification and Mobile Application Integration. *Heliyon*. 2024;10(8).
24. Srinivasan S, Prabin SM, Mathivanan SK, Rajadurai H, Kulan-daivelu S, Shah MA. Sugarcane Leaf Disease Classification Using Deep Neural Network Approach. *BMC Plant Biology*. 2025;25(1):282.
25. Chaganti SY, Nanda I, Pandi KR, Prudhvith TG, Kumar N. Image Classification using SVM and CNN. In: *2020 International Conference on Computer Science, Engineering and Applications (ICCSEA)*. IEEE; 2020. p. 1-5.
26. Suwitono YA, Kaunang FJ. Implementasi Algoritma Convolutional Neural Network (CNN) untuk Klasifikasi Daun dengan Metode Data Mining SEMMA Menggunakan Keras. *Jurnal Komtika*. 2022;6(2).
27. Dåderman A, Rosander S. Evaluating Frameworks for Implementing Machine Learning in Signal Processing: A Comparative Study of CRISP-DM, SEMMA and KDD; 2018.
28. Thite S, Suryawanshi Y, Patil K, Chumchu P. Sugarcane Leaf Dataset: A Dataset for Disease Detection and Classification for Machine Learning Applications. *Data in Brief*. 2024;53:110268.
29. Ahmed NA. What is a Confusion Matrix in Machine Learning? The Model Evaluation Tool Explained; 2024. Accessed: 2024-11-10. Available from: <https://www.datacamp.com/tutorial/what-is-a-confusion-matrix-in-machine-learning>.