

instiper 15

jurnal_22945

 14 Maret 2025-2

 Cek Plagiat

 INSTIPER

Document Details

Submission ID

trn:oid::1:3185138129

Submission Date

Mar 17, 2025, 7:54 AM GMT+7

Download Date

Mar 17, 2025, 7:56 AM GMT+7

File Name

Jurnal_Hansjansen_Ong_2021.docx

File Size

5.1 MB

10 Pages

3,135 Words

20,213 Characters

4% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- ▶ Bibliography
- ▶ Quoted Text

Top Sources

- 4%  Internet sources
- 2%  Publications
- 1%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

No suspicious text manipulations found.

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 4% Internet sources
- 2% Publications
- 1% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	repository.its.ac.id	<1%
2	Internet	text-id.123dok.com	<1%
3	Student papers	KYUNG HEE UNIVERSITY	<1%
4	Internet	www.ioinformatic.org	<1%
5	Publication	Shazifa Azhari, Nining Rahaningsih, Raditya Danar Dana, Mulyawan .. "PENINGKA...	<1%
6	Internet	e-journal.uajy.ac.id	<1%
7	Internet	arvindodrone.com	<1%
8	Internet	liupurnomo.com	<1%
9	Internet	peerj.com	<1%
10	Internet	repository.poltekkes-kdi.ac.id	<1%

AGROFORETECH

Volume XX, Nomor XX, Tahun XXXX

STUDI DETEKSI KONDISI KESEHATAN TANAMAN MENGUNAKAN CITRA UAV DENGAN METODE CONVOLUTIONAL NEURAL NETWORK

Hansjansen Ong^{*1}, Tatik Suhartati², Sugeng Wahyudiono²

^{1 2}Fakultas Kehutanan Institut Pertanian STIPER Yogyakarta

^{*)}Email Korespondensi: hansjansenong1@gmail.com

ABSTRAK

Pemantauan kesehatan tanaman Eukaliptus secara akurat dan efisien menjadi kunci dalam pengelolaan hutan tanaman industri. Penelitian ini bertujuan mengembangkan sistem deteksi kesehatan tanaman berbasis citra UAV (*Unmanned Aerial Vehicle*) dan *Convolutional Neural Network* (CNN) untuk mengidentifikasi tajuk sehat (hijau) dan stres (coklat). Data citra UAV resolusi tinggi (2 cm/piksel) diambil menggunakan drone DJI Phantom 4 Pro V2.0 di Estate Tesso, PT. Riau Andalan Pulp and Paper, Provinsi Riau. Metode meliputi pra-pemrosesan citra (*histogram stretching, patching*), pembuatan *synthetic dataset* untuk menyeimbangkan kelas minoritas, serta pelatihan model YOLOv7 dengan arsitektur CSPDarknet53. Evaluasi menggunakan metrik *mean Average Precision* (mAP), *precision, recall*, dan *F1-Score*. Hasil menunjukkan model mencapai akurasi rata-rata 98,18% pada lima sampel uji, dengan *precision* 89,93% dan *recall* 97,93% untuk kelas hijau, serta *precision* 95,17% dan *recall* 93,96% untuk kelas coklat. Kelas coklat memiliki *F1-Score* lebih rendah (0,6–0,7) akibat ketidakseimbangan data dan tumpang tindih visual dengan latar belakang. Penelitian ini berkontribusi pada deteksi dini stres tanaman dan efisiensi pengelolaan hutan berbasis data.

Kata Kunci: Berisi tiga sampai lima kata/frasa dengan tanda baca titik koma pemisah.

PENDAHULUAN

Pemantauan kesehatan tanaman menjadi semakin krusial dalam menghadapi berbagai tantangan global, seperti perubahan iklim dan peningkatan kebutuhan pangan. Metode konvensional, seperti inspeksi visual manual, terbukti tidak efisien untuk area yang luas. Sebagai solusi, teknologi UAV (*drone*) menawarkan efisiensi lebih tinggi dengan kemampuannya untuk mengumpulkan data visual yang mencakup area yang luas dalam waktu singkat. Salah satu parameter penting yang dapat dianalisis adalah warna tajuk tanaman, yang dapat menggambarkan kondisi kesehatan tanaman secara keseluruhan. Melalui analisis warna tajuk, dapat dideteksi adanya stres, penyakit, serta kekurangan nutrisi pada tanaman.

Integrasi UAV dengan *Convolutional Neural Network* (CNN) memungkinkan pemrosesan data visual secara lebih efektif. Sistem ini dirancang untuk meningkatkan efisiensi pemantauan tanaman, khususnya pada hutan tanaman industri monokultur Eukaliptus, yang

merupakan bahan baku utama bagi industri pulp dan kertas. Data citra dikumpulkan menggunakan drone DJI Phantom V.2 Pro pada ketinggian 100 meter.

Pemantauan hutan Eukaliptus melalui analisis warna tajuk menggunakan UAV telah terbukti efektif dalam mendeteksi stres tanaman (Maddikunta et al., 2020; Pratyarningsih et al., 2024). Penggunaan UAV dalam pertanian presisi memungkinkan pemantauan yang lebih cepat dan efisien (Megat et al., 2021). UAV yang dilengkapi dengan sensor multispektral dan hyperspektral berperan penting dalam pengumpulan data secara real-time yang mendukung pengelolaan tanaman (Frigioescu et al., 2023; Junarto & Djurjani, 2020)

CNN, yang pertama kali diperkenalkan oleh Lecun et al. (1998), telah berkembang menjadi teknologi dasar dalam pengolahan citra. Model CNN terbaru, seperti AlexNet (Krizhevsky et al., 2017), menunjukkan performa tinggi dalam tugas klasifikasi gambar. Integrasi CNN dengan data yang diperoleh melalui UAV memungkinkan analisis yang lebih mendalam untuk pemantauan kondisi tanaman secara *real-time* (Zhang & Kovacs, 2012) Penelitian terkini menunjukkan bahwa penerapan CNN dalam pertanian dapat meningkatkan akurasi deteksi dan meminimalkan kesalahan dalam proses deteksi (Kamilaris & Prenafeta-Boldú, 2018).

YOLO (Redmon et al., 2016) merupakan metode deteksi objek yang memproses citra dalam satu kali evaluasi, yang meningkatkan kecepatan dan akurasi deteksi. Penelitian oleh Wibowo et al. (2023) menunjukkan bahwa metode YOLO dapat meningkatkan akurasi dan kecepatan deteksi dalam konteks pertanian. Keberhasilan YOLO dalam deteksi objek juga telah terbukti dalam berbagai bidang, termasuk pertanian dan penanggulangan bencana (Desy Siswanti et al., n.d.; Sarosa & Muna, 2021)

Penelitian terdahulu menunjukkan keberhasilan berbagai teknologi dalam pemantauan kesehatan tanaman. Yana Armanto et al. (2024) menggunakan CNN dan YOLO untuk mendeteksi pohon kelapa sawit, sementara Gupta (2024) berfokus pada peningkatan akurasi analisis warna tajuk tanaman Eukaliptus melalui augmentasi data. Safe'I et al. (2024) membuktikan kemampuan CNN dalam mendeteksi kerusakan pohon dengan akurasi tinggi. Fricker et al. (2019) menggunakan kombinasi CNN, LiDAR, dan citra hyperspektral untuk mengidentifikasi spesies pohon, sementara Wang et al. (2019) mengembangkan metode pengenalan kebakaran hutan menggunakan CNN bersama dengan pengolahan citra tradisional.

METODE PENELITIAN

Penelitian ini dilakukan di Estate Tesso East dan Estate Tesso West, PT. Riau Andalan Pulp and Paper (RAPP), Provinsi Riau, dengan fokus pada hutan tanaman industri Eukaliptus monokultur. Lokasi dipilih karena karakteristik tajuk tanaman yang konsisten, memudahkan pengambilan data citra UAV. Penelitian dilaksanakan selama 3 bulan, mulai dari Juli hingga September 2024. Rincian waktu penelitian adalah sebagai berikut: pengambilan data citra UAV pada 31 Juli 2024, pra-pemrosesan data pada Agustus 2024 (2 minggu), pelatihan dan validasi model pada Agustus–September 2024 (4 minggu), serta pengujian dan analisis hasil pada September 2024 (2 minggu).

Peralatan yang digunakan dalam penelitian ini meliputi:

1. Perangkat Keras: Drone DJI Phantom 4 Pro V2.0 dengan sensor RGB, laptop Lenovo ITL G14, dan server berbasis Google Colab Pro untuk komputasi cloud.
2. Perangkat Lunak: Python 3.9 dengan library OpenCV dan PyTorch, Roboflow untuk augmentasi data, Labellmg untuk segmentasi dan anotasi citra, serta Visual Studio Code untuk pemrograman.

3. Bahan: Citra udara dari UAV dengan resolusi 2 cm/piksel, dataset anotasi yang melabeli citra tajuk Eukaliptus sebagai "hijau" (sehat) dan "coklat" (stres), serta dataset sintesis untuk menyeimbangkan kelas "coklat".

Penelitian ini menggunakan citra udara yang diambil pada tanaman Eukaliptus umur 21 bulan. Pengambilan citra dilakukan dengan drone DJI Phantom 4 Pro V2.0 menggunakan pola grid dengan overlap 80% untuk cakupan optimal. Data citra diproses menggunakan Python 3.9 dengan *library* PyTorch dan OpenCV, serta perangkat lunak Roboflow dan Labellmg untuk manajemen dataset dan anotasi.

Model YOLOv7 dengan *backbone* CSPDarknet53 dipilih untuk deteksi objek real-time dan akurasi tinggi. Model dilatih dengan dataset citra yang telah dianotasi dan diuji dengan metrik seperti mAP, *precision*, *recall*, dan *F1-Score*. Evaluasi melibatkan analisis kesalahan komisi dan omisi untuk menilai keakuratan deteksi model. Dengan langkah penelitian sebagai berikut:

1. Data citra yang diperoleh melalui UAV diproses menjadi dataset untuk model CNN. Pengumpulan dataset dilakukan pada 31 Juli 2024, dengan pengaturan drone di ketinggian 100 meter, kecepatan 32 km/j, dan resolusi 5472 × 3078 piksel. Proses pra-pemrosesan meliputi koreksi warna dengan metode *histogram stretching*, *patching* citra, dan segmentasi tajuk pohon untuk memisahkan elemen relevan. Labellmg digunakan untuk anotasi citra, dengan penandaan kondisi tajuk "hijau" dan "coklat".
2. Karena jumlah tajuk coklat pada dataset asli sedikit, dataset sintesis dibuat dengan mengubah warna tajuk hijau menjadi coklat. Hal ini bertujuan untuk menyeimbangkan kelas "coklat" dalam dataset. Setelah itu, dilakukan eliminasi citra yang terdistorsi atau mengandung objek yang tidak relevan, seperti hutan alam.
3. Kemudian model dilatih dengan dataset yang telah dipersiapkan, di mana dataset ini dibagi menggunakan metode stratified sampling dengan rasio 70:20:10 untuk data *training*, *validation*, dan *testing*, untuk menghindari *class imbalance*. Model mempelajari pola dari data pelatihan, dan validasi digunakan untuk menghindari *overfitting*. Proses pelatihan menggunakan metode *cloud-based* untuk mempercepat komputasi. Model kemudian diuji pada citra UAV untuk mendeteksi dan mengklasifikasikan kondisi kesehatan tajuk pohon Eukaliptus.
4. Validasi model dilakukan dengan evaluasi kuantitatif dan uji lapangan. Model diuji menggunakan metrik mAP, *precision*, *recall*, dan *F1-Score*, serta diuji lapangan dengan membandingkan deteksi otomatis terhadap penghitungan manual pada lima sampel. Kesalahan komisi dan omisi dihitung untuk mengukur akurasi deteksi model. Evaluasi ini bertujuan untuk memastikan keandalan hasil deteksi otomatis yang dihasilkan oleh model.

Hasil akhir penelitian adalah model deteksi yang telah dilatih dan diuji, yang mampu mendeteksi kondisi kesehatan tanaman Eukaliptus berdasarkan citra UAV. Model ini menggunakan teknologi CNN untuk mendeteksi stres, defisiensi nutrisi, atau serangan penyakit pada tanaman. Model ini diharapkan dapat memberikan prediksi yang akurat tentang kesehatan tanaman dan mendukung pengelolaan lahan secara berkelanjutan.

HASIL DAN PEMBAHASAN

A. Pengaplikasian Model

5 Sampel akan dipilih karena masing-masing dari sampel menggambarkan berbagai kondisi yang biasa ditemui di lapangan.

Tabel 1. Hasil Analisis Pengaplikasian Kinerja Model

Area	Total Aktual	Hasil Deteksi	Error Lebih	Error Kurang	Benar	Error Komisi	Error Omisi	Akurasi
Sampel 1	138	135	0	3	135	0,000	0,022	97,83%
Sampel 2	117	113	1	4	112	0,009	0,034	95,73%
Sampel 3	18	19	1	0	18	0,053	0,000	100,00%
Sampel 4	142	142	0	0	142	0,000	0,000	100,00%
Sampel 5	113	110	0	3	110	0,000	0,027	97,35%
Total	528	519	2	10	517			
Rata-rata Akurasi								98,18%

Pada penerapan model ini terhadap lima sampel uji, terdeteksi sebanyak 509 pohon pada kelas *Green* dan 10 pohon pada kelas *Brown*. Pengujian ini menunjukkan bahwa model berhasil mendeteksi pohon dengan tajuk coklat pada berbagai kondisi area, yang mengindikasikan keberhasilan model dalam mendeteksi secara otomatis tajuk pohon berwarna coklat. Meskipun jumlah tajuk coklat pada citra sampel relatif sedikit, model ini mampu mengidentifikasi tajuk coklat yang tersebar di berbagai variabel lingkungan.

Hasil uji akurasi menunjukkan bahwa semua sampel memiliki kesalahan komisi yang rendah dengan sampel 3 dan sampel 4 memiliki tingkat kesalahan yang paling rendah yaitu 0,000. Hal ini menunjukkan bahwa sistem deteksi jarang kali mendeteksi objek yang tidak ada atau tidak relevan, yang menunjukkan keakuratan dalam mendeteksi hanya pohon yang sesuai dengan kriteria. Begitu pula dengan kesalahan omisi yang bervariasi pada tiap sampel, namun dengan nilai kesalahan terendah pada Sampel 3 dan Sampel 4, yang mencapai 0,000. Hal ini menunjukkan bahwa pada sampel-sampel tersebut, sistem hampir tidak melewatkan pohon yang seharusnya terdeteksi. Namun, pada Sampel 1, Sampel 2, dan Sampel 5, ada sedikit kesalahan omisi, yang artinya beberapa pohon tidak terdeteksi.

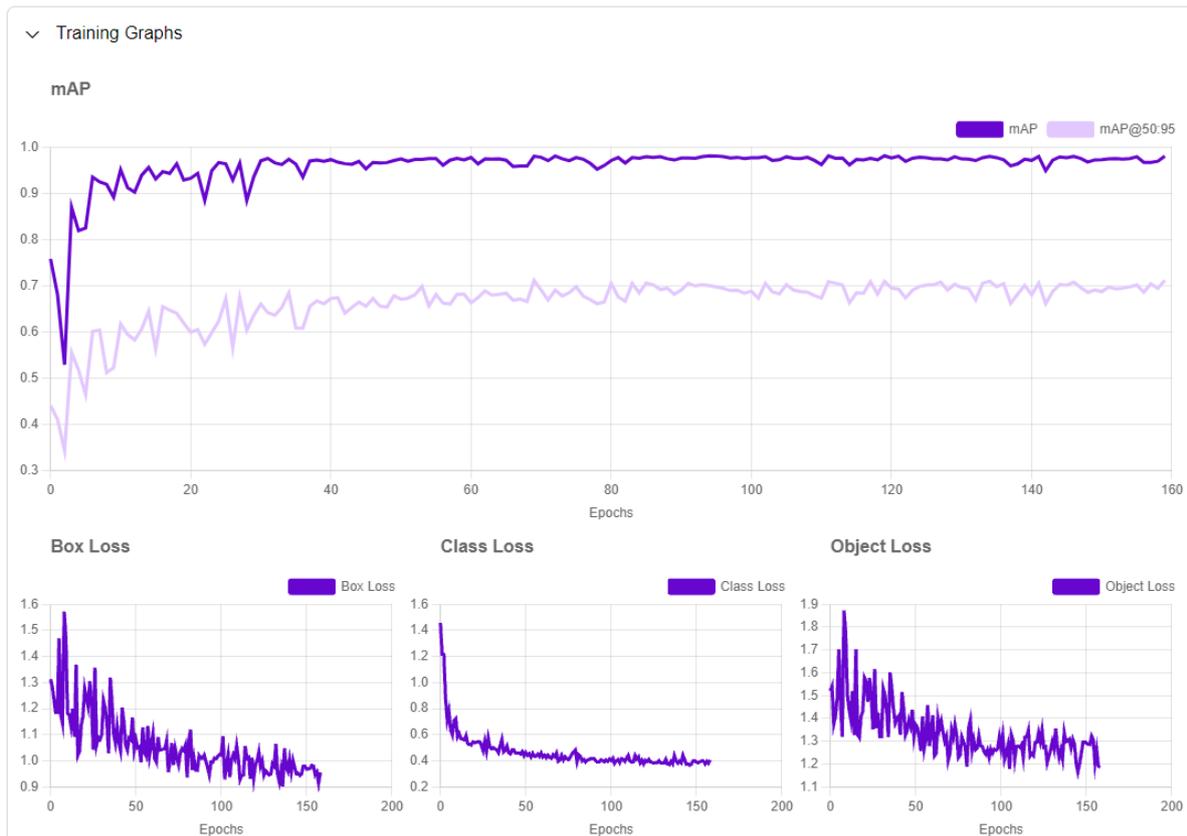
B. Analisis Kinerja Model Deteksi Otomatis

Penelitian ini menghasilkan model deteksi kesehatan tanaman berbasis CNN dengan algoritma YoloV7 yang efektif menganalisis warna tajuk pohon Eukaliptus dari citra UAV. Model ini menunjukkan kinerja baik dalam mengklasifikasikan tajuk hijau (sehat) dan coklat (stres), dengan tingkat kehilangan data yang minim.

Berdasarkan grafik pelatihan pada Gambar 1, kinerja model berkembang seiring dengan peningkatan jumlah epoch. Model dievaluasi menggunakan metrik utama *mean Average Precision* (mAP) dan mAP@50:95. Nilai mAP mencerminkan *precision* rata-rata model dalam mengidentifikasi dan melokalisasi tajuk pohon pada berbagai ambang batas IoU (*Intersection over Union*), sementara mAP@50:95 menunjukkan kinerja model pada rentang IoU 50% hingga 95%, yang berwarna ungu pudar. Tingginya nilai mAP@50:95 menunjukkan kemampuan model yang stabil dalam mendeteksi objek dengan presisi baik, bahkan pada kondisi tumpang tindih yang kompleks. Terdapat peningkatan progresif nilai mAP dan mAP@50:95, yang mencerminkan kemampuan model dalam mengidentifikasi objek dengan presisi lebih tinggi seiring bertambahnya epoch.

Pada fungsi *loss*, ketiga komponen—*Box Loss*, *Class Loss*, dan *Object Loss*—menunjukkan penurunan signifikan seiring bertambahnya *epoch*. *Box Loss* mengalami

penurunan stabil pada *epoch* 50–160, menandakan peningkatan akurasi prediksi lokasi objek. *Class Loss* juga mengalami penurunan, yang menunjukkan peningkatan kemampuan model dalam membedakan kelas objek. Sementara itu, *Object Loss* menunjukkan penurunan, mengindikasikan peningkatan stabilitas deteksi. Penurunan ketiga fungsi *loss* ini sejalan dengan peningkatan presisi, membuktikan konsistensi model. Proses pelatihan mencapai stabilisasi pada *epoch* 100–160, di mana peningkatan mAP dan penurunan *loss* mulai melambat, menandakan model telah mendekati titik konvergensi optimal.



Gambar 1. Grafik Hasil Pelatihan Model

Untuk mengevaluasi keseimbangan antara precision dan recall, digunakan grafik yang memvisualisasikan perbandingan nilai F1-Score antara kelas "Bad" (tajuk coklat/stres) dan "Good" (tajuk hijau/sehat).

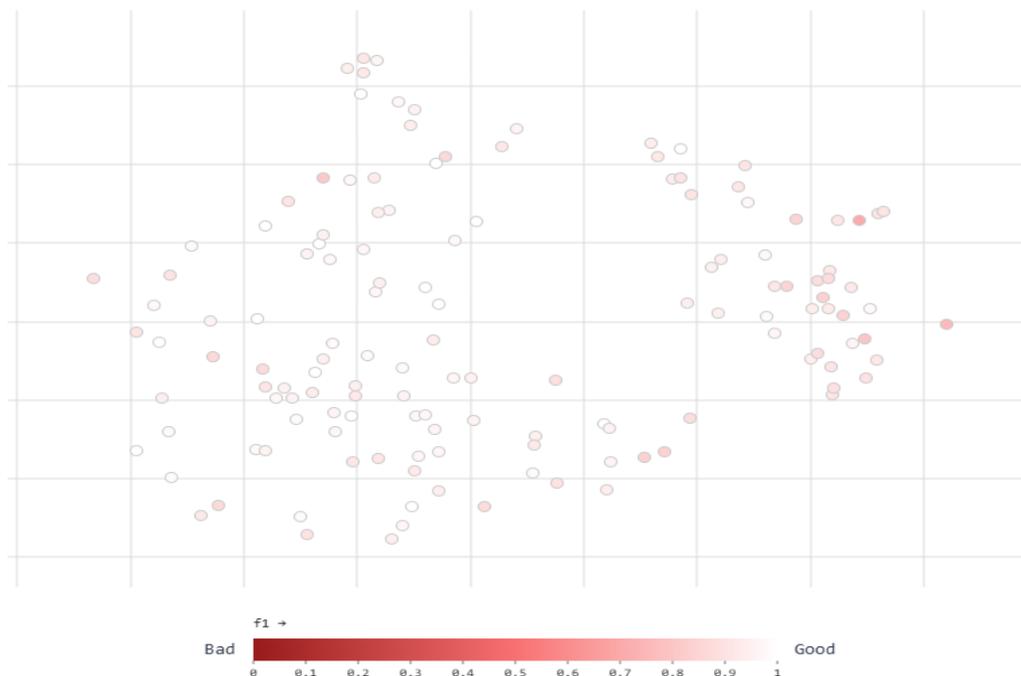
Berdasarkan Gambar 2, kelas hijau memiliki F1-Score tertinggi pada rentang 0.8–1.0, menunjukkan kinerja model yang sangat baik dalam mengidentifikasi tajuk sehat. Sebaliknya, kelas coklat memiliki F1-Score yang lebih rendah, dengan puncak pada rentang 0.6–0.7, disebabkan oleh dua faktor utama:

1. Ketidakseimbangan dataset, di mana jumlah sampel tajuk coklat lebih sedikit daripada hijau, menyulitkan model dalam mempelajari pola spesifik kelas coklat, meskipun ada augmentasi data sintesis.
 2. Karakteristik visual tajuk coklat yang tumpang tindih dengan latar belakang (seperti tanah kering atau bayangan), meningkatkan risiko false positive dan false negative.
- Perbandingan dengan penelitian sebelumnya menunjukkan temuan serupa, dengan Gupta (2024) mencapai F1-Score 92% setelah augmentasi intensif dan Safe'i et al. (2024) 100% dengan dataset seimbang. Meski F1-Score rata-rata penelitian ini

mencapai 95,9%, disparitas antara kelas hijau dan coklat menunjukkan perlunya optimasi tambahan, seperti:

1. Menambah variasi dataset dengan citra tajuk coklat dalam kondisi lingkungan yang beragam.
2. Meningkatkan teknik augmentasi untuk memperkaya dataset kelas coklat.
3. Menyesuaikan bobot kelas coklat selama pelatihan untuk menyeimbangkan pembelajaran model.

Hasil ini menunjukkan bahwa integrasi UAV-CNN efektif mendeteksi kondisi sehat tanaman, terutama kelas hijau. Namun, peningkatan deteksi untuk kelas coklat diperlukan agar model lebih komprehensif. Analisa confusion matrix pada Gambar 17 menunjukkan True Positive (TP) pada diagonal, False Negative (FN) untuk prediksi salah, dan False Positive (FP) untuk prediksi kelas lain yang salah.



Gambar 2. Grafik Distribusi *F1-Score*

Berikutnya adalah hasil analisa *confusion matrix* yang dapat dilihat pada gambar 3, yang dimana *True Positive* (TP) pada bagian diagonal, yang berarti prediksi benar untuk kelas tersebut. *False Negative* (FN) yang menandakan kasus kelas tersebut yang salah diprediksi sebagai kelas lain. Dan *False Positive* (FP) yang menandakan kasus kelas lain yang salah diprediksi sebagai kelas tersebut.

Berikut adalah penjelasan kinerja model:

1. Kolom 1 (Prediksi *Brown*)
 - a) Baris 1 (Ground Truth *Brown*, Prediksi *Brown*): 296
Ini adalah True Positive untuk kelas *Brown*. Artinya, 296 gambar yang benar-benar berlabel *Brown* berhasil diprediksi dengan benar sebagai *Brown*.
 - b) Baris 2 (Ground Truth *Green*, Prediksi *Brown*): 2
Ini adalah False Negative untuk kelas *Green*. Artinya, ada 2 gambar yang seharusnya *Green*, tetapi model salah memprediksi mereka sebagai *Brown*.
 - c) Baris 3 (False Positive untuk *Brown*): 15
Ini adalah False Positive untuk kelas *Brown*. Artinya, ada 15 gambar yang seharusnya bukan *Brown*, tetapi model salah memprediksi mereka sebagai *Brown*.

2. Kolom 2 (Prediksi *Green*)
 - a) Baris 1 (Ground Truth *Brown*, Prediksi *Green*): 1
Ini adalah False Negative untuk kelas *Brown*. Artinya, ada 1 gambar yang sebenarnya berlabel *Brown*, tetapi model salah memprediksi gambar tersebut sebagai *Green*.
 - b) Baris 2 (Ground Truth *Green*, Prediksi *Green*): 3128
Ini adalah True Positive untuk kelas *Green*. Artinya, 3,128 gambar yang benar-benar berlabel *Green* berhasil diprediksi dengan benar sebagai *Green*.
 - c) Baris 3 (False Positive untuk *Green*): 350
Ini adalah False Positive untuk kelas *Green*. Artinya, ada 350 gambar yang seharusnya bukan *Green*, tetapi model salah memprediksi mereka sebagai *Green*.
3. Kolom 3 (False Negative)
 - a) Baris 1 (Ground Truth *Brown*, Prediksi False Negative): 19
Ini adalah False Negative untuk kelas *Brown*. Artinya, ada 19 gambar yang benar-benar berlabel *Brown*, tetapi model tidak berhasil memprediksi mereka sebagai *Brown*, dan malah gagal mendeteksinya.
 - b) Baris 2 (Ground Truth *Green*, Prediksi False Negative): 66
Ini adalah False Negative untuk kelas *Green*. Artinya, ada 66 gambar yang benar-benar berlabel *Green*, tetapi model salah memprediksi mereka sebagai *Brown*, atau model gagal mendeteksinya sebagai *Green*.
 - c) Baris 3 (False Positive untuk False Negative): 0
Kolom ini menunjukkan bahwa tidak ada gambar yang secara keliru diprediksi sebagai "False Negative" tanpa dasar yang benar.

Berikut adalah Perhitungan untuk nilai *precision* dan *recall* dari kedua kelas, yang dilakukan untuk mengevaluasi seberapa baik model dalam membuat prediksi yang benar, terutama dalam konteks data yang tidak seimbang atau ketika penting untuk memahami kinerja model dalam mengenali masing-masing kelas secara adil.

1. Kelas *Brown*
 - a) *Precision*

$$\frac{TP}{TP + FP} = \frac{296}{296 + 15} = 95,17\%$$

- b) *Recall*

$$\frac{TP}{TP + FN} = \frac{296}{296 + 19} = 93,96\%$$

2. Kelas *Green*
 - a) *Precision*

$$\frac{TP}{TP + FP} = \frac{3128}{3128 + 350} = 89,93\%$$

- b) *Recall*

$$\frac{TP}{TP + FN} = \frac{3128}{3128 + 66} = 97,93\%$$

Meskipun model memiliki akurasi tinggi dalam memprediksi *Green*, terdapat kesalahan prediksi pada kedua kelas, terutama False Positives dan False Negatives, yang menunjukkan adanya ruang untuk perbaikan, terutama dalam mendeteksi kelas *Brown* yang lebih jarang.

		PREDICTION		
		Brown	Green	False Negative
GROUND TRUTH	Brown	296	1	19
	Green	2	3128	66
	False Positive	15	350	0

Gambar 3. Confusion Matrix dari model deteksi

KESIMPULAN

Penelitian ini berhasil mengembangkan model deteksi kesehatan tanaman berbasis CNN dengan algoritma YOLOv7 untuk mengidentifikasi kondisi tajuk pohon Eukaliptus menggunakan citra UAV. Model ini menunjukkan kinerja yang sangat baik dalam mendeteksi tajuk hijau (sehat) dengan akurasi tinggi, serta mampu mendeteksi tajuk coklat (stres), meskipun terdapat beberapa tantangan. Kinerja model diukur dengan metrik seperti *mean Average Precision (mAP)*, *precision*, *recall*, dan *F1-Score*, yang menunjukkan hasil yang solid dengan rata-rata akurasi 98,18% pada lima sampel uji.

Namun, model ini mengalami kesulitan dalam mendeteksi kelas coklat, terutama karena ketidakseimbangan dataset dan tumpang tindih visual dengan latar belakang, yang meningkatkan jumlah *false positives* dan *false negatives*. Diperlukan optimasi lebih lanjut, termasuk peningkatan variasi dataset dan teknik augmentasi untuk kelas coklat. Meskipun demikian, integrasi UAV dan CNN terbukti efektif dalam pemantauan kesehatan tanaman secara otomatis, memberikan kontribusi signifikan terhadap efisiensi pengelolaan lahan dan deteksi dini stres tanaman. Ke depan, penelitian ini dapat dilanjutkan dengan memperbaiki kinerja model pada kelas minoritas dan melakukan evaluasi lebih luas di berbagai kondisi lingkungan.

DAFTAR PUSTAKA

Desy Siswanti, S., Fali, A., Ubaya, H., Saladin, I., Mubaroq, G., Komputer, S., Sriwijaya, U., & Elektro, T. (n.d.). Deteksi Objek Serupa Menggunakan You Only Look Once (YOLO3.0). *JSI: Jurnal Sistem Informasi (E-Journal)*, 15(2), 2023. <http://ejournal.unsri.ac.id/index.php/jsi/index>

- Fricker, G. A., Ventura, J. D., Wolf, J. A., North, M. P., Davis, F. W., & Franklin, J. (2019). A convolutional neural network classifier identifies tree species in mixed-conifer forest from hyperspectral imagery. *Remote Sensing*, 11(19). <https://doi.org/10.3390/rs11192326>
- Frigioescu, T. F., Condruz, M. R., Badea, T. A., & Paraschiv, A. (2023). A Preliminary Study on the Development of a New UAV Concept and the Associated Flight Method. *Drones*, 7(3). <https://doi.org/10.3390/drones7030166>
- Gupta, A. (2024). Predicting Forest Areas Susceptible to Fire Risk Using Convolutional Neural Networks. *Journal of Information Systems and Informatics*, 6(3). <https://doi.org/10.51519/journalisi.v6i3.788>
- Junarto, R., & Djurjani, D. (2020). Pemanfaatan Teknologi Unmanned Aerial Vehicle (UAV) untuk Pemetaan Kadaster. *BHUMI: Jurnal Agraria Dan Pertanahan*, 6(1). <https://doi.org/10.31292/jb.v6i1.428>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/J.COMPAG.2018.02.016>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). *ImageNet Classification with Deep Convolutional Neural Networks*. <http://code.google.com/p/cuda-convnet/>
- Lecun, Y., Bottou, L., Bengio, Y., Haffner, P., & Bottou, E. (1998). Gradient-based Learning Applied To Document Recognition - Proceedings of the IEEE. *Proceedings of the IEEE*, 86(11). <https://doi.org/10.1109/5.726791i>
- Maddikunta, P. K. R., Hakak, S., Alazab, M., Bhattacharya, S., Gadekallu, T. R., Khan, W. Z., & Pham, Q.-V. (2020). *Unmanned Aerial Vehicles in Smart Agriculture: Applications, Requirements and Challenges*. <https://doi.org/10.1109/JSEN.2021.3049471>
- Megat Mohamed Nazir, Megat Najib, Terhem, R., Norhisham, A. R., Mohd Razali, S., & Meder, R. (2021). Early monitoring of health status of plantation-grown eucalyptus pellita at large spatial scale via visible spectrum imaging of canopy foliage using unmanned aerial vehicles. *Forests*, 12(10). <https://doi.org/10.3390/f12101393>
- Pratyaningsih, S. R., Suwarno, E., & Sadjati, E. (2024). Potensi Penyerapan Karbon Dan Pemantauan Kesehatan Pohon Eucalyptus Pellita Di Universitas Lancang Kuning, Pekanbaru, Riau. *Jurnal Hutan Tropis*, 12(1), 72-79.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. <http://pjreddie.com/yolo/>
- Safe'i, R., Andrian, R., Maryono, T., Tapasya, S., & Gandadipoera, F. H. M. (2024). Assessment of Tree Damage with the Forest Health Monitoring (FHM) Method and the Convolutional Neural Network (CNN) Method. *IOP Conference Series: Earth and Environmental Science*, 1352(1). <https://doi.org/10.1088/1755-1315/1352/1/012049>
- Sarosa, M., & Muna, N. (2021). *Implementasi Algoritma You Only Look Once (YOLO) untuk Deteksi Korban Bencana Alam*. 8(4). <https://doi.org/10.25126/jtiik.202184407>
- Wang, Y., Dang, L., & Ren, J. (2019). Forest fire image recognition based on convolutional neural network. *Journal of Algorithms and Computational Technology*, 13. <https://doi.org/10.1177/1748302619887689>
- Wibowo, A., Lusiana, L., & Dewi, T. K. (2023). Implementasi Algoritma Deep Learning You Only Look Once (YOLOv5) Untuk Deteksi Buah Segar Dan Busuk. *Paspalum: Jurnal Ilmiah Pertanian*, 11(1), 123. <https://doi.org/10.35138/paspalum.v11i1.489>
- Yana Armanto, D., Agustian Hudjimartsu, S., & Hermawan, E. (2024). Identifikasi Perhitungan Pohon Kelapa Sawit Otomatis dengan Menggunakan Metode Convolutional Neural Network (CNN). In *Jurnal Mahasiswa Teknik Informatika* (Vol. 8, Issue 3).
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. In *Precision Agriculture* (Vol. 13, Issue 6, pp. 693–712). <https://doi.org/10.1007/s11119-012-9274-5>

