

METODE DETEKSI POKOK POHON SECARA AUTOMATIS PADA CITRA PERKEBUNAN SAWIT MENGGUNAKAN MODEL CONVOLUTIONAL NEURAL NETWORK (CNN) PADA PERANGKAT LUNAK SISTEM INFORMASI GEOGRAFIS

Samuel^{*1}, Kestrilia Rega Prilianti², Hendry Setiawan³, Prasetyo Mimboro⁴

^{1,2,3}Universitas Ma Chung, Malang, ⁴PT Perkebunan Nusantara IV, Medan
Email: ¹311810029@student.machung.ac.id, ²kestrilia.rega@machung.ac.id,
³hendry.setiawan@machung.ac.id, ⁴prasetyomimboro@gmail.com

*Penulis Korespondensi

(Naskah masuk: 08 Desember 2022, diterima untuk diterbitkan: 27 Desember 2022)

Abstrak

Perkebunan sawit merupakan salah satu bisnis yang diminati oleh industri baik di dalam maupun luar negeri. Perkebunan sawit di Indonesia dengan lahan yang sangat luas merupakan sumber pendapatan negara yang potensial. Namun, proses monitoring menjadi tantangan tersendiri jika dilakukan secara manual. Oleh karena itu diperlukan terobosan inovasi agar proses monitoring dapat dilakukan secara efisien namun tetap akurat. Teknologi penginderaan jauh dapat diterapkan sebagai solusi. Dengan menggunakan *Unmanned Aerial Vehicle* (UAV) citra perkebunan dapat direkam. Selanjutnya dengan implementasi pengolahan citra digital dan kecerdasan buatan, citra dapat dimanfaatkan untuk melakukan monitoring berdasarkan warna dari pohon sawit. Tahap pertama yang diperlukan dalam akuisisi data untuk berbagai keperluan monitoring adalah deteksi pokok pohon sawit secara otomatis. Pada penelitian ini didemonstrasikan penggunaan metode *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-34 dan ResNet-50 untuk membangun model deteksi pokok pohon sawit dari citra UAV perkebunan sawit PTPN IV. Tujuan deteksi pokok pohon adalah untuk melakukan analisis lanjutan terkait kondisi pohon sawit seperti status nutrisi, kesiapan panen dan indikasi adanya serangan penyakit. Model ResNet yang telah dilatih berhasil melakukan proses deteksi pokok pohon sawit secara otomatis dengan akurasi *training* sebesar 84% dan akurasi *testing* rata-rata sebesar 71%. Metode deteksi diterapkan dengan menggunakan perangkat lunak sistem informasi geografis.

Kata kunci: citra, CNN, perkebunan sawit, sistem informasi geografis, UAV

THE METHOD OF AUTOMATIC TREE DETECTION ON OIL PALM PLANTATION IMAGES USING CONVOLUTIONAL NEURAL NETWORK (CNN) MODEL USING GEOGRAPHIC INFORMATION SYSTEM SOFTWARE

Abstract

Oil palm plantations are one of the businesses that are in demand by both local and international industries. Oil palm plantations in Indonesia with very large lands are a very potential source of income for the country. However, the monitoring process related to disease attack and nutritional status becomes a challenge if it is done manually. Therefore, innovation breakthroughs are needed so that the monitoring process can be carried out efficiently but still accurately. Remote sensing technology can be applied as a solution. By using *Unmanned Aerial Vehicle* (UAV) plantation images can be recorded. Furthermore, with the implementation of digital image processing and artificial intelligence, the image can be used to monitor based on the color of the palm tree. The first step needed in image processing for various monitoring purposes is the automatic detection of oil palm trees. This study demonstrates the use of the *Convolutional Neural Network* (CNN) method with the ResNet-34 and ResNet-50 architectures to build a palm tree principal detection model from UAV images of PTPN IV oil palm plantations. The purpose of tree detection is to carry out further analysis related to the condition of oil palm trees such as nutritional status, harvest readiness and indications of disease attacks.. The ResNet model that has been trained has successfully carried out the process of detecting oil palm trees automatically with training accuracy of 84%, testing accuracy of 73% and 69%. The detection method is applied using geographic information system software.

Keywords: digital image, CNN, oil palm plantation, geographic information system, UAV

1. PENDAHULUAN

Kelapa sawit (*Elaeis guineensis* Jacq) merupakan salah satu jenis komoditi yang diminati oleh bidang usaha perkebunan. Negara Indonesia merupakan salah satu negara yang menghasilkan komoditas sawit yang besar. Perkebunan sawit di Indonesia tersebar di 26 provinsi yang terletak pada pulau Sumatera, Kalimantan, Jawa, dan Papua. Pohon sawit memiliki bentuk menyerupai palem memiliki batang pohon yang mencapai ketinggian 24 meter.

Luas perkebunan sawit di Indonesia sekitar 14.33 juta hektar dan memproduksi sebesar 42.9 juta ton minyak sawit pada tahun 2018. Pada tahun 2019 luas perkebunan sawit di Indonesia tumbuh sebanyak 1.88% menjadi 14.60 juta hektar dan produksi meningkat sebesar 12.92% menjadi 48.42 juta ton (B.P.S, 2019). Pada tahun 2020 luas areal perkebunan sawit tidak mengalami perubahan besar. Proporsi perkebunan yang dimiliki oleh perusahaan swasta sebesar 54,69%, dimiliki oleh perkebunan rakyat sebesar 41,44%, dan dimiliki oleh negara sebesar 3,87%. Fakta lain menunjukkan bahwa produksi minyak sawit pada tahun 2020 mengalami penurunan sebesar 44,76 ton dari tahun sebelumnya. Hal ini diklaim merupakan dampak pandemi *Covid-19* (B.P.S, 2020).

Kemajuan teknologi informasi yang begitu pesat dan cepat dapat bermanfaat di berbagai bidang, salah satunya adalah *precision agriculture*. Sebagai contoh, dengan bantuan teknologi penginderaan jauh, perkebunan sawit dapat dimonitor dengan lebih mudah dan murah. Citra perkebunan dapat direkam menggunakan *Unmanned Aerial Vehicle* (UAV) seperti *drone*. Citra perkebunan sawit selanjutnya dapat digunakan untuk melakukan evaluasi serangan penyakit maupun status nutrisi tanaman. Proses awal yang diperlukan adalah deteksi pokok pohon sawit. Pokok pohon sawit yang telah terdeteksi selanjutnya dapat lebih mudah diambil datanya lebih lanjut. Agar efisien, proses ini harus terjadi secara otomatis. Dalam konsep penginderaan jauh, yang dimaksud data pada umumnya adalah warna dari tanaman yang terekam pada citra. Warna merupakan reflektansi tanaman terhadap cahaya matahari pada panjang gelombang tertentu. Perilaku reflektansi ini diketahui berkorelasi kuat dengan berbagai kondisi tanaman.

Algoritma komputasi yang berkembang semakin canggih memungkinkan komputer atau mesin dapat belajar layaknya manusia. *Deep Learning* merupakan salah satu algoritma komputasi yang terbukti sangat baik dalam melakukan klasifikasi citra (Alfredo & , 2022). Salah satu metode *deep learning* yang dapat digunakan untuk mengenali pokok pohon sawit pada citra perkebunan secara otomatis adalah *Convolutional Neural Network* (CNN). Dengan adanya model deteksi objek pokok pohon sawit, sistem mampu melakukan *counting* pohon sawit secara otomatis. Prasvita dkk (2021) melakukan identifikasi dan perhitungan pokok pohon

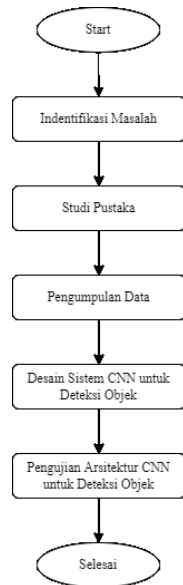
secara otomatis dengan membandingkan metode CNN dan *fusi* LiDAR. Pada klasifikasi menggunakan CNN dengan citra RGB, didapatkan akurasi tertinggi sebesar 98% sedangkan dengan *fusi* LiDAR didapatkan akurasi tertinggi sebesar 97%. Arrofiqoh & Harintaka (2018) memanfaatkan metode CNN untuk melakukan proses deteksi 5 jenis tanaman (padi, bawang merah, kelapa, pisang, dan cabai) pada citra UAV resolusi tinggi dan diperoleh akurasi sebesar 93%. Penelitian lainnya juga dilakukan oleh Nauthika dkk (2017) dengan menggunakan metode LiDAR dan diperoleh akurasi sebesar 95%. Ultami dkk (2022) menggunakan citra *google earth* beresolusi tinggi dan citra *drone* untuk melakukan perhitungan pohon sawit secara otomatis dengan menerapkan metode *Template Matching*. Diketahui bahwa hasil deteksi pokok pohon lebih baik jika citra input yang digunakan adalah citra *drone*. Metode Faster R-CNN dengan arsitektur ResNet juga diketahui dapat digunakan untuk melakukan deteksi pokok pohon (Zheng, et al., 2021). Akurasi Faster R-CNN dengan arsitektur ResNet-50 diketahui lebih baik dibandingkan akurasi yang diberikan oleh Faster R-CNN dengan menggunakan FPN.

Yarak dkk (2021) membandingkan arsitektur ResNet-50 dan VGG-16 untuk melakukan deteksi pohon sawit sehat dan sakit. Arsitektur VGG-16 memberikan *F1-Score* sebesar 76.47%, sedangkan arsitektur ResNet-50 memberikan *F1-Score* sebesar 86.96% untuk deteksi sawit sakit. Untuk deteksi sawit sehat arsitektur VGG-16 memberikan *F1-Score* sebesar 88.7% dan ResNet-50 memberikan *F1-Score* sebesar 92.07%. Metode Faster R-CNN diketahui juga sangat baik dalam melakukan identifikasi pohon sawit dengan *F1-Score* sebesar 97.57% (Liu, et al., 2020).

Atas laporan keberhasilan model CNN pada penelitian-penelitian tersebut, maka pada penelitian ini didemonstrasikan sistem deteksi pokok pohon sawit secara otomatis dengan menggunakan metode CNN arsitektur Resnet-34 dan ResNet-50 pada citra UAV perkebunan sawit PT Perkebunan Nusantara (PTPN) IV. Arsitektur ResNet-50 dan ResNet-101 dilaporkan dapat memberikan hasil yang sangat baik dalam mendeteksi pohon kelapa (Iqbal, et al., 2020). Pada penelitian arsitektur ResNet-34 dan ResNet-50 digunakan dan dibandingkan untuk membuat model deteksi pohon sawit pada citra *drone* di ketinggian 300 m. Model dibuat dengan bantuan aplikasi sistem informasi geografis ArcGIS Pro.

2. METODE PENELITIAN

Penelitian dimulai dari identifikasi masalah dan studi literatur. Dilanjutkan dengan proses perancangan model dan diakhiri dengan pengujian kinerja model sebagaimana yang tampak pada Gambar 1.



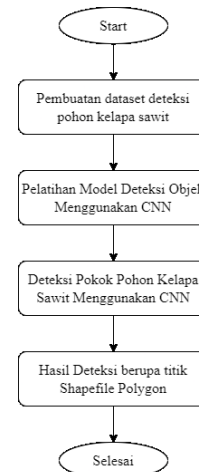
Gambar 1. Diagram Alir Penelitian

2.1 Perangkat Keras dan Perangkat Lunak

Pada penelitian ini terdapat 2 komponen yang dibutuhkan yaitu komponen perangkat keras dan perangkat lunak. Perangkat keras yang digunakan pada penelitian ini adalah laptop Asus ROG GL553VD. Perangkat lunak yang digunakan adalah Aplikasi ArcGIS Pro. Pada aplikasi ArcGIS Pro terdapat *libraries deep learning* yang berfungsi untuk menyelesaikan permasalahan *object detection*, *semantic segmentation*, *pixel classification*, *feature selection*, dan lain sebagainya. Library tersebut dapat bekerja pada berbagai *framework* seperti *tensorflow*, *keras*, *pytorch*, dan *fast.ai*.

2.2 Tahapan Pengembangan Model

Pengembangan arsitektur *Convolutional Neural Network* (CNN) dimulai dengan pembuatan *dataset*. *Dataset* harus dipersiapkan baik untuk proses *training* maupun *testing*. Selanjutnya adalah memilih arsitektur CNN dan melatihnya sehingga dihasilkan model terbaik. Model kemudian digunakan untuk melakukan deteksi pokok pohon secara otomatis. Luaran dari hasil deteksi berupa *shape file point* yang menunjukkan lokasi terdeteksinya pokok pohon sawit. Alur pengembangan model CNN dapat dilihat pada Gambar 2.



Gambar 2. Alur Desain Sistem CNN

2.3 Dataset

Dataset pada penelitian ini adalah citra UAV perkebunan sawit milik PTPN IV lengkap dengan berbagai perangkat spasialnya. Terdapat 6 set citra dari lokasi yang sama (Gunung Bayu, Sumatera Utara) namun diambil pada bulan yang berbeda-beda sebagaimana yang tampak pada Tabel 1.

Tabel 1. Rincian Data Citra UAV yang Terkoleksi

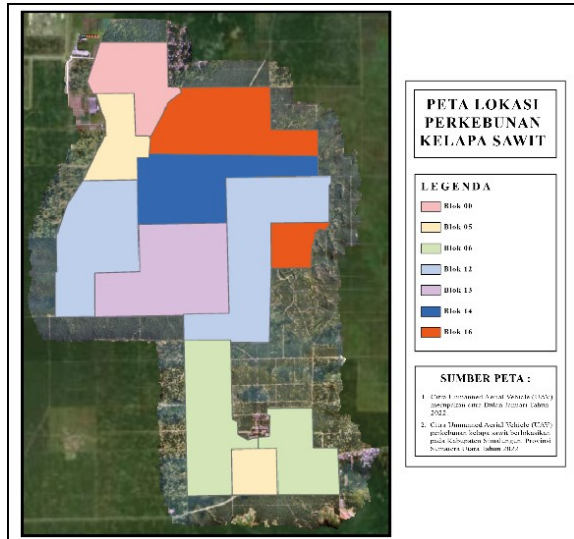
No	Nama File	Ektensi	Bulan	Tahun	Ukuran
1	Citra 1	TIFF	Agustus	2021	9.06 GB
2	Citra 2	TIFF	November	2021	9.65 GB
3	Citra 3	TIFF	Januari	2022	38.9 GB

Gambar 3 adalah contoh citra mentah yang akan diproses lebih lanjut. Citra tersebut diambil dengan kamera yang dilekatkan pada *drone*. *Drone* diterbangkan pada ketinggian 300 m.



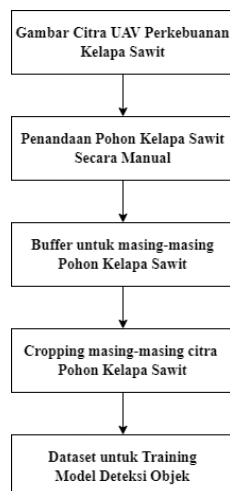
Gambar 3. Citra UAV Perkebunan Sawit PTPN IV Gunung Bayu, Sumatera Utara

Perkebunan sawit PTPN IV terbagi menjadi beberapa blok penanaman sebagaimana yang tampak pada Gambar 4. Pada penelitian ini, area perkebunan yang dianalisis meliputi 7 blok yaitu blok 00, blok 05, blok 06, blok 12, blok 13, blok 14, dan blok 16.



Gambar 4. Pembagian Blok penanaman Pohon Sawit PTPN IV Gunung Bayu

Untuk membuat data *training* terdapat beberapa tahapan sebagaimana yang tampak pada Gambar 5. Tahap pertama akan melakukan koleksi citra UAV perkebunan sawit. Selanjutnya adalah melakukan penandaan pohon sawit secara manual. Tahap ketiga adalah melakukan proses *buffer* terhadap area pohon sawit. *Buffer* pada titik pohon sawit digunakan untuk pengenalan pohon sawit berdasarkan luas tajuk pada rentang umur pohon sawit (Stefano, 2019). Tahap selanjutnya adalah melakukan proses *cropping* terhadap masing-masing pokok pohon sawit. Hasil *cropping* inilah yang kemudian digunakan sebagai data *training* oleh algoritma CNN.



Gambar 5. Bagan Proses Pembuatan Dataset

Untuk menandai pokok pohon sawit diperlukan bantuan file *Shapefile Point* (SHP). *Shapefile* adalah sebuah format data vektor yang digunakan untuk

menyimpan lokasi, bentuk, dan fitur geografis. Sehingga *Shapefile Point* digunakan untuk menyimpan penanda pokok pohon dalam bentuk titik (*point*) yang selanjutnya digunakan sebagai alat bantu dalam membuat data *training* untuk melatih model CNN. Penanda pokok pohon dibuat secara manual. Data *training* dibuat dengan melakukan *cropping* berdasarkan petunjuk pokok pohon yang sudah disimpan pada file SHP (lihat Gambar 6). Hasil *cropping* dapat dilihat pada Gambar 7.



Gambar 6. Shapefile Point pada masing-masing blok perkebunan sawit PTPN IV



Gambar 7. Contoh data training

Data *training* diambil dari citra pada 3 bulan yang berbeda yakni Agustus 2021, November 2021, dan Januari 2022. Data *training* Agustus 2021 memiliki total sub citra sebanyak 16042. Data November 2021 memiliki total sub citra sebanyak 16987, sedangkan data *training* Januari 2022 memiliki total sub citra sebanyak 60817. Untuk setiap set data *training* ditetapkan model CNN terbaik dan untuk setiap model terbaik dievaluasi dengan menggunakan data *testing* yang berasal dari citra UAV di bulan yang berbeda.

2.4 Model CNN

Model CNN dibangun dengan menggunakan arsitektur ResNet-34 dan ResNet-50 yang telah tersedia pada perangkat lunak ArcGIS Pro. ResNet merupakan kepanjangan dari *Residual Network*. ResNet merupakan sebuah arsitektur CNN yang

menggunakan model yang telah dilatih sebelumnya. Dasar arsitektur ResNet adalah CNN yang terdiri dari *convolutional layer*, *pooling layer*, dan *fully connected layer* serta penambahan beberapa *skip connection* pada setiap *convolution layer* (Ridhovan & Suharso, 2022). Fungsi aktivasi *softmax* digunakan pada *layer output*. Fungsi aktivasi *softmax* adalah fungsi aktivasi yang biasa digunakan pada *output layer* untuk kasus klasifikasi. *Layer output* memiliki banyak kesamaan dengan *fully connected layer*. Perbedaan antara kedua layer tersebut adalah fungsi aktivasi yang digunakan. Pada *output layer* akan menggunakan fungsi aktivasi *softmax*, sedangkan pada *layer fully connected layer* digunakan fungsi aktivasi ReLU. Fungsi aktivasi ReLU dapat dilihat pada Persamaan (2). Persamaan fungsi aktivasi *softmax* dapat dilihat pada Persamaan (1) dibawah ini.

$$S(y)_i = \frac{\exp(y_i)}{\sum_{j=1}^n \exp(y_j)} \quad (1)$$

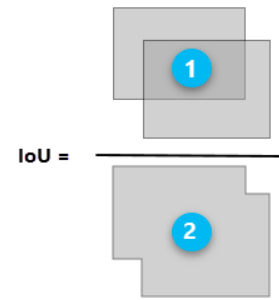
$$f(x) = \max(0, x) \quad (2)$$

2.4 Tuning Parameter Model CNN

Proses *tuning* parameter untuk model CNN dilakukan dengan mengevaluasi *F1-Score*. Adapun parameter yang diuji coba adalah *Intersection over Union* (IoU). Nilai IoU digunakan untuk mengatur batas toleransi pengenalan pokok pohon sawit dengan membandingkan sub citra pada data *training* dengan sub citra hasil prediksi. Rentang nilai IoU berada pada 0 hingga 1, semakin besar nilai IoU menunjukkan semakin akurat objek yang terdeteksi oleh model (Ramasari, et al., 2021). Rumus Kalkulasi nilai IoU dapat dilihat pada persamaan (3).

$$IoU = \frac{Aktual \cap Prediksi}{Aktual \cup Prediksi} \quad (3)$$

Ilustrasi konsep IoU dapat dilihat pada Gambar 8. Semakin besar nilai IoU maka semakin ketat syarat sebuah sub citra akan diterima/diklasifikasi sebagai pokok pohon sawit. Sebaliknya, semakin rendah nilai IoU semakin longgar syarat sebuah sub citra dapat diterima/diklasifikasi sebagai pokok pohon sawit. Terdapat 3 nilai IoU yang diujicoba pada penelitian ini yaitu 0.1, 0.5, dan 1. Nilai IoU akan digunakan untuk menghitung nilai *Precision*, *Recall*, dan *F1-Score* (Sugandi & Hartono, 2022). Rumus perhitungan nilai *Precision*, *Recall*, dan *F1-Score* dapat dilihat pada persamaan (4), (5), dan (6). Untuk masing-masing nilai tersebut dievaluasi akurasi model CNN dalam melakukan proses deteksi pokok pohon sawit secara otomatis pada citra masukan.



Gambar 8. Ilustrasi Persamaan IoU

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$F1 - Score = 2 \times \left(\frac{Recall \times Precision}{Recall + Precision} \right) \quad (6)$$

Parameter lain yang digunakan dalam penelitian ini dapat dilihat pada Tabel 2 dan Tabel 3. Parameter tersebut tidak diujicoba melainkan ditetapkan berdasarkan pengalaman dari penelitian sebelumnya.

Tabel 2. Parameter Pengujian Model Pada Data *Training*

Parameter	Hypertuning Parameter
<i>Padding</i>	56
<i>Threshold</i>	0.5
<i>Nms_Overlap</i>	0.3
<i>Batch Size</i>	10
<i>Max Overlap Ratio</i>	0.3

Tabel 3. Parameter Pengujian Model Pada Data *Testing*

Parameter	Hypertuning Parameter
<i>Padding</i>	56
<i>Threshold</i>	0.25
<i>Nms_Overlap</i>	0.1
<i>Batch Size</i>	10
<i>Max Overlap Ratio</i>	0.1

3. HASIL DAN PEMBAHASAN

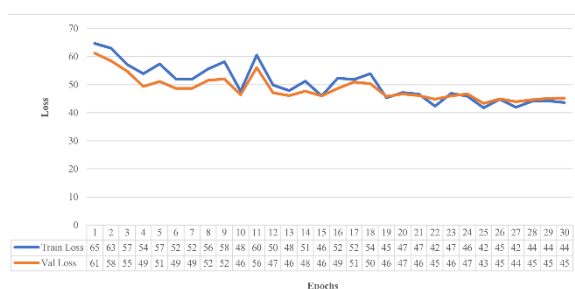
3.1. Model CNN untuk Citra UAV bulan Agustus 2021

Sebanyak tiga pengaturan berbeda untuk model ResNet-50 diterapkan pada citra UAV bulan Agustus 2021. Pengaturan parameter yang digunakan untuk *training* model CNN dapat dilihat pada Tabel 4.

Tabel 4. Pengaturan Parameter *Training* Model CNN pada Citra Bulan Agustus 2021

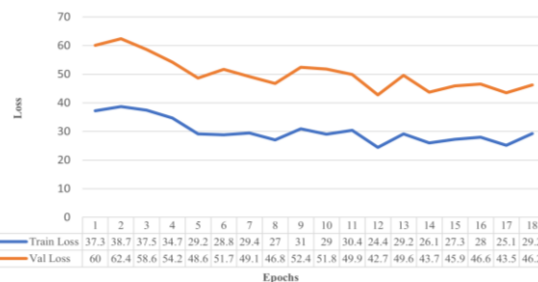
no	model name	arsitektur	batch size	epoch	Learning rate	%val data
1	Model AUG 21 Pertama		5	30	0.001	30%
2	Model AUG 21 Kedua	ResNet-50	5	30	0.001	35%
3	Model AUG 21 Ketiga		10	30	0.001	30%

Evaluasi *training loss* dan *validation loss* untuk pengaturan pertama dapat dilihat pada Gambar 9. Dari grafik dapat dilihat tidak ada indikasi *underfitting*. Selain itu tampak bahwa nilai *training loss* dan *validation loss* juga saling berdekatan yang menunjukkan tidak ada indikasi *overfitting*. Setelah 30 *epoch*, dihasilkan rata-rata *training loss* sebesar 50.284 sedangkan rata-rata *validation loss* 48.572. Dapat disimpulkan bahwa pada percobaan ini model berhasil dengan baik mendeteksi pokok pohon sawit, selain itu juga mempunyai kemampuan generalisasi yang baik.



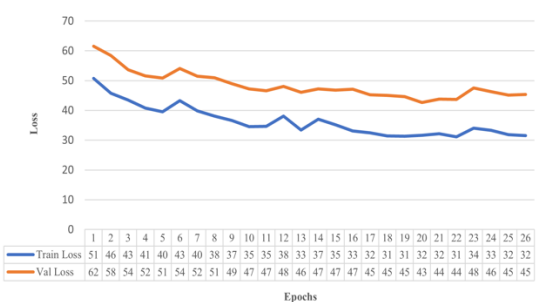
Gambar 9. Evaluasi *Training Loss* dan *Validation Loss* Model Agustus 2021 dengan Pengaturan Parameter Pertama

Evaluasi *training loss* dan *validation loss* untuk pengaturan kedua dapat dilihat pada Gambar 10. Dari grafik dapat dilihat bahwa nilai *training loss* dan *validation loss* saling berjauhan yang menunjukkan keadaan *overfitting* yang cukup parah. Setelah 18 *epoch*, proses *training* dihentikan karena tidak menunjukkan perbaikan pada nilai *loss*. Dapat disimpulkan bahwa pada percobaan ini model tidak berhasil mendeteksi pokok pohon sawit dengan baik karena kemampuan generalisasinya buruk.



Gambar 10. Evaluasi *Training Loss* dan *Validation Loss* Model Agustus 2021 dengan Pengaturan Parameter Kedua

Evaluasi *training loss* dan *validation loss* untuk pengaturan ketiga dapat dilihat pada Gambar 11. Sebagaimana yang ditemukan pada percobaan pengaturan kedua, nilai *training loss* dan *validation loss* saling berjauhan yang menunjukkan keadaan *overfitting*. Setelah 26 *epoch*, proses *training* dihentikan karena nilai *loss* tidak menunjukkan trend perbaikan yang memadai. Dapat disimpulkan bahwa pada percobaan ini model juga tidak berhasil mendeteksi pokok pohon sawit dengan baik karena tidak didukung oleh kemampuan generalisasi yang baik.



Gambar 11. Evaluasi *Training Loss* dan *Validation Loss* Model Agustus 2021 dengan Pengaturan Parameter Ketiga

3.2. Model CNN untuk Citra UAV bulan November 2021

Pada percobaan ini digunakan dua arsitektur yaitu ResNet-34 dan ResNet-50. Sebanyak dua pengaturan berbeda diterapkan untuk proses *training* pada masing-masing arsitektur. Pengaturan parameter yang digunakan untuk *training* model CNN dapat dilihat pada Tabel 5.

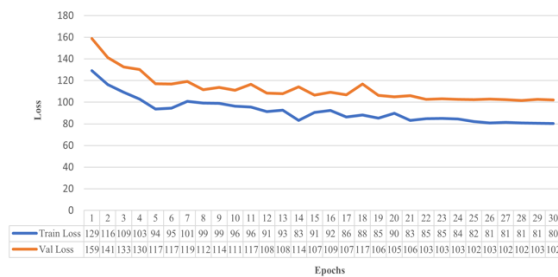
Tabel 5. Pengaturan Parameter *Training* Model CNN pada CitranBulan November 2021

no	model name	arsitektur	batch size	epoch	learning rate	%val data
1	Model NOV 21 Pertama	ResNet-34	12	30	0.001	30%
2	Model NOV 21 Kedua	ResNet-34	12	30	AUTO	25%

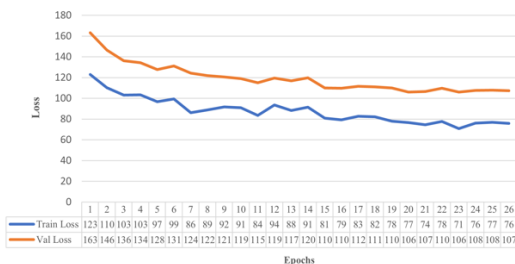
Tabel 5. (Lanjutan)

no	model name	arsitektur	batch size	epoch	learning rate	%val data
3	Model NOV 21 Ketiga	ResNet-50	10	30	0.001	30%
4	Model NOV 21 Ke-empat	ResNet-50	15	30	0.001	30%

Evaluasi *training loss* dan *validation loss* untuk pengaturan pertama dapat dilihat pada Gambar 12. Dari grafik terlihat adanya selisih nilai *training loss* dan *validation loss*. Hal ini berpotensi menghasilkan keadaan *overfitting*. Setelah 30 *epoch*, diperoleh rata-rata *training loss* sebesar 91.983, sedangkan rata-rata *validation loss* sebesar 112.628. Nilai ini lebih buruk dibandingkan percobaan untuk citra bulan Agustus 2021.

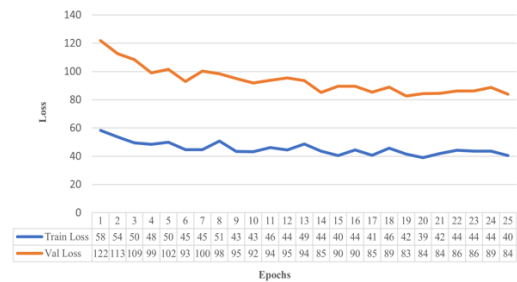
Gambar 12. Evaluasi *Training Loss* dan *Validation Loss* Model November 2021 dengan Pengaturan Parameter Pertama

Evaluasi *training loss* dan *validation loss* untuk pengaturan kedua dapat dilihat pada Gambar 13. Dari grafik terlihat adanya selisih nilai *training loss* dan *validation loss* yang cukup besar. Hal ini menunjukkan keadaan *overfitting*. Setelah 26 *epoch*, *training* dihentikan dan diperoleh rata-rata *training loss* sebesar 87.724, sedangkan rata-rata *validation loss* sebesar 119.186. Nilai ini tidak berbeda jauh dari hasil percobaan sebelumnya

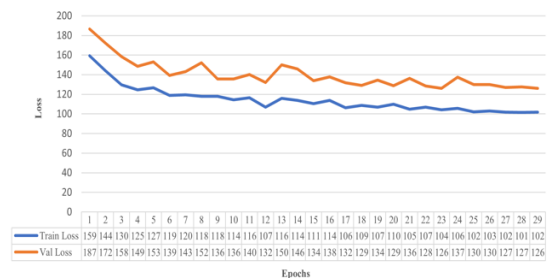
Gambar 13. Evaluasi *Training Loss* dan *Validation Loss* Model November 2021 dengan Parameter Kedua

Evaluasi *training loss* dan *validation loss* untuk pengaturan ketiga dapat dilihat pada Gambar 14. Dari grafik dapat dilihat bahwa nilai *training loss* dan *validation loss* saling berjauhan yang menunjukkan keadaan *overfitting* yang cukup parah. Setelah 25 *epoch*, proses *training* dihentikan karena tidak menunjukkan perbaikan pada nilai *loss*. Dapat disimpulkan bahwa pada percobaan ini model tidak

berhasil mendeteksi pokok pohon sawit dengan baik karena kemampuan generalisasinya buruk.

Gambar 14. Evaluasi *Training Loss* dan *Validation Loss* Model November 2021 dengan Pengaturan Parameter Ketiga

Evaluasi *training loss* dan *validation loss* untuk pengaturan keempat dapat dilihat pada Gambar 15. Dari grafik dapat dilihat bahwa nilai *training loss* dan *validation loss* saling berjauhan yang juga menunjukkan keadaan *overfitting*. Setelah 29 *epoch*, proses *training* dihentikan karena tidak menunjukkan perbaikan pada nilai *loss*. Dapat disimpulkan bahwa pada percobaan ini model tidak berhasil mendeteksi pokok pohon sawit dengan baik karena kemampuan generalisasinya kurang memadai.

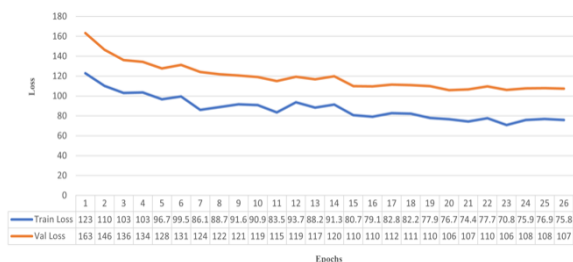
Gambar 15. Evaluasi *Training Loss* dan *Validation Loss* Model November 2021 dengan Parameter Ke-empat

3.3. Model CNN untuk Citra UAV bulan Januari 2022

Pada percobaan ini digunakan dua arsitektur yaitu ResNet-34 dan ResNet-50. Pengaturan parameter yang digunakan untuk *training* model CNN dapat dilihat pada Tabel 6.

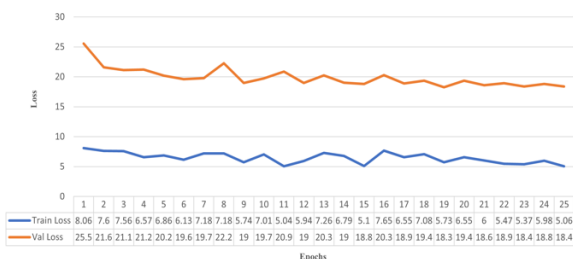
Tabel 6. Parameter Training Model CNN Bulan Januari 2022

no	model name	arsitektur	batch size	epoch	learning rate	%val data
1	Model JAN 22 Pertama	ResNet-34	64	50	AUTO	10%
2	Model JAN 22 Kedua	ResNet-50	10	30	0.001	25%



Gambar 16. Evaluasi *Training Loss* dan *Validation Loss* Model Januari 2022 dengan Pengaturan Parameter Pertama

Evaluasi *training loss* dan *validation loss* untuk pengaturan pertama dapat dilihat pada Gambar 16. Dari grafik dapat dilihat bahwa nilai *training loss* dan *validation loss* saling berjauhan yang juga menunjukkan keadaan *overfitting*. Setelah 26 *epoch*, proses *training* dihentikan karena tidak menunjukkan perbaikan pada nilai *loss*. Dapat disimpulkan bahwa pada percobaan ini model tidak berhasil mendeteksi pokok pohon sawit dengan baik karena kemampuan generalisasinya tidak memadai.



Gambar 17. Evaluasi *Training Loss* dan *Validation Loss* Model Januari 2022 dengan Pengaturan Parameter Kedua

Evaluasi *training loss* dan *validation loss* untuk pengaturan kedua dapat dilihat pada Gambar 17. Dari grafik dapat dilihat bahwa nilai *training loss* dan *validation loss* berbeda sangat jauh yang menunjukkan keadaan *overfitting* parah. Setelah 25 *epoch*, proses *training* dihentikan karena tidak menunjukkan perbaikan pada indikasi *overfitting*. Meskipun nilai *loss* yang dihasilkan lebih kecil dari percobaan-percobaan sebelumnya, namun selisih *training loss* dan *validation loss* yang besar menunjukkan model tidak akan dapat memprediksi data baru dengan baik. Oleh karena itu model tidak layak digunakan.

3.4. Hasil Tes Model CNN Deteksi Pokok Pohon Sawit

Pada bagian ini dilakukan evaluasi terhadap akurasi deteksi pokok pohon oleh masing-masing model CNN yang telah dilatih dan dievaluasi pada tahap pengembangan model. Indikator yang digunakan adalah *F1-Score* yang didasarkan 3 nilai *Intersection over Union* (IoU). Nilai *Intersection over Union* digunakan untuk mengatur toleransi perbedaan hasil prediksi dan *ground truth*. Hasil pengujian model pada data *training* dapat dilihat pada Tabel 7. Tampak bahwa nilai IoU sebesar 1 dan 0.5 tidak dapat digunakan karena terlalu ketat dalam mentolerir

perbedaan titik pohon. Oleh karena itu selanjutnya nilai IoU 0.1 yang digunakan untuk implementasi di lapangan.

Tabel 7. Evaluasi Nilai *F1-Score* Model CNN pada Data *Training*

No	Model Name	IoU	<i>F1-Score</i>	Bulan
1	Model AUG 21 Pertama	0.1	0.7689	AUG 21
		0.5	0.2837	
		1	0	
2	Model AUG 21 Kedua	0.1	0.7371	AUG 21
		0.5	0.2614	
		1	0	
3	Model AUG 21 Ketiga	0.1	0.7235	AUG 21
		0.5	0.2634	
		1	0	
4	Model NOV 21 Pertama	0.1	0.8461	NOV 21
		0.5	0.4410	
		1	0	
5	Model NOV 21 Kedua	0.1	0.7791	NOV 21
		0.5	0.3544	
		1	0	
6	Model NOV 21 Ketiga	0.1	0.8214	NOV 21
		0.5	0.3572	
		1	0	
7	Model NOV 21 Ke-empat	0.1	0.8105	NOV 21
		0.5	0.4434	
		1	0	
8	Model JAN 22 Pertama	0.1	0.9102	JAN 22
		0.5	0.4672	
		1	0	
9	Model JAN 22 Kedua	0.1	0.8954	JAN 22
		0.5	0.5151	
		1	0	

Tabel 8 menunjukkan hasil pengujian model pada data *testing*. Sebagaimana kondisi yang ditemukan pada data *training*, nilai IoU 1 dan 0.5 juga tidak dapat diterapkan lebih lanjut karena dengan pengaturan tersebut tidak satupun pokok pohon dapat diidentifikasi.

Model CNN terbaik yang dilatih dengan citra bulan Agustus 2021 adalah arsitektur ResNet-50 dengan parameter *batch size* 5, *learning rate* 0.001, dan *validation data* sebesar 30%. Akurasi deteksi dengan indikator *F1-Score* pada data *training* adalah sebesar 76%, sedangkan akurasi model bulan Agustus pada data *testing* citra Januari 2022 mendapatkan *F1-Score* sebesar 54% dan data *testing* citra November 2021 mendapatkan nilai *F1-Score* sebesar 48%.

Model CNN terbaik yang dilatih dengan citra bulan November 2021 adalah arsitektur ResNet-50 dengan parameter *batch size* 5, *learning rate* 0.001, dan *validation data* sebesar 30%. Akurasi deteksi dengan indikator *F1-Score* pada data *training* adalah

sebesar 84%, sedangkan akurasi model bulan November 2021 pada data *testing* citra Januari 2022 mendapatkan *F1-Score* sebesar 73% dan data *testing* citra Agustus 2021 mendapatkan nilai *F1-Score* sebesar 69%.

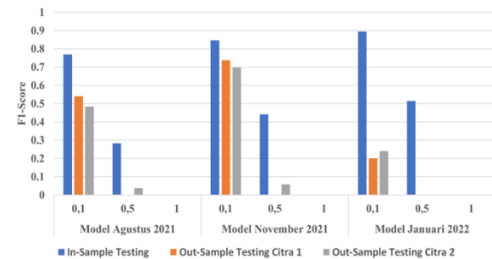
Tabel 8. Evaluasi Nilai *F1-Score* Model CNN Pada Data *Testing*

No	Model Name	Io U	Data Testing			
			<i>F1-Score</i>	Bulan	<i>F1-Score</i>	Bulan
1	Model AUG 21 Pertama	0.1	0.5409	JAN 22	0.4843	NOV 21
		0.5	0		0.0379	
		1	0		0	
2	Model AUG 21 Kedua	0.1	0.6628	JAN 22	0.6575	NOV 21
		0.5	0		0.0866	
		1	0		0	
3	Model AUG 21 Ketiga	0.1	0.5778	JAN 22	0.5764	NOV 21
		0.5	0.054		0.000031	
		1	0		0	
4	Model NOV 21 Pertama	0.1	0.8461	JAN 22	0.6978	AUG 21
		0.5	0.441		0.0588	
		1	0		0	
5	Model NOV 21 Kedua	0.1	0.8219	JAN 22	0.5872	AUG 21
		0.5	0.0006		0.0357	
		1	0		0	
6	Model NOV 21 Ketiga	0.1	0.689	JAN 22	0.7232	AUG 21
		0.5	0		0.0589	
		1	0		0	
7	Model NOV 21 Ke-empat	0.1	0.6299	JAN 22	0.6738	AUG 21
		0.5	0		0.0517	
		1	0		0	
8	Model JAN 22 Pertama	0.1	0.3687	NOV 21	0.3535	AUG 21
		0.5	0		0	
		1	0		0	
9	Model JAN 22 Kedua	0.1	0.2003	NOV 21	0.2405	AUG 21
		0.5	0		0	
		1	0		0	

Model CNN terbaik yang dilatih dengan citra bulan Januari 2022 adalah arsitektur ResNet-50 dengan parameter *batch size* 10, *learning rate* 0.001, dan *validation data* sebesar 25%. Akurasi deteksi dengan indikator *F1-Score* pada data *training* adalah sebesar 89%, sedangkan akurasi model bulan Januari 2022 pada data *testing* citra agustus 2021 mendapatkan *F1-Score* sebesar 24% dan data *testing* citra November 2021 mendapatkan nilai *F1-Score* sebesar 20%.

3.5. Ringkasan Model CNN Terbaik Untuk Deteksi Pohon Sawit

Grafik perbandingan nilai *F1-Score* terbaik pada bulan Agustus 2021, November 2021, dan Januari 2022 berdasarkan nilai IoU dapat dilihat pada Gambar 18.



Gambar 18. Perbandingan Nilai *F1-Score* terbaik Pada masing-masing Bulan Berdasarkan Nilai IoU

Tampak bahwa model terbaik untuk melakukan proses deteksi pokok pohon sawit adalah model yang dilatih dengan citra bulan November 2021. Model November pertama merupakan model terbaik dalam melakukan proses deteksi pokok pohon sawit pada citra UAV. Berdasarkan nilai *F1-Score* pada model November 2021 dengan menggunakan nilai IoU 0.1 model mendapatkan akurasi yang memuaskan sedangkan model Agustus 2021 dan Januari 2022 kurang baik dalam melakukan deteksi pokok pohon sawit pada citra baru. Konfigurasi pelatihan model pertama November 2021 terbaik dapat dilihat pada Tabel 9.

Tabel 9. Konfigurasi Training CNN Model Pertama November 2021

Parameter	Hyper Tuning Parameter
Backbone Model	Single-Shot Detector
Arsitektur	ResNet-34
Batch Size	12
Learning Rate	0.001
Validation Data	30%
Epochs	30

4. KESIMPULAN

Pada penelitian ini telah dihasilkan model deteksi pokok pohon sawit menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-34. Model yang dilatih dengan citra UAV perkebunan di bulan November 2021 diketahui merupakan model terbaik dengan nilai *F1-Score* untuk proses *training* sebesar 84%. Rata-rata nilai *F1-Score* untuk data *testing* adalah sebesar 71%. Kendala yang mempengaruhi kurang maksimalnya pencapaian akurasi dalam mendeteksi pokok pohon sawit adalah kualitas citra UAV yang berbeda-beda. Meskipun citra diambil pada lokasi yang sama namun perbedaan waktu dan perbedaan kondisi cuaca menyebabkan hasil rekaman kamera yang dibawa oleh UAV juga berbeda. Oleh karena itu, untuk

penelitian selanjutnya disarankan terdapat algoritma untuk preproses citra terlebih dahulu.

DAFTAR PUSTAKA

- ALFREDO, I. & S., 2022. Perbaikan Model Alexnet Untuk Mendeteksi Kematangan Tbs Kelapa Sawit Dengan Menggunakan Image Enhancement Dan Hyperparameter Tuning. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 27(1), Pp. 56 - 68.
- ARROFIQOH, E. N. & H., 2018. Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi. *Geomatika*, Pp. 61-68.
- B. P. S., 2019. *STATISTIK KELAPA SAWIT INDONESIA 2019*. Jakarta: Badan Pusat Statistik.
- B. P. S., 2020. *STATISTIK KELAPA SAWIT INDONESIA 2020*. Jakarta: Badan Pusat Statistik.
- IQBAL, M. S., ALI, H., TRAN, S. N. & IQBAL, T., 2020. Coconut Trees Detection And Segmentation In Aerial Imagery Using Mask Region-Based Convolution Neural Network. *Iet Computer Vision*, Pp. 428-439.
- LIU, X., GHAZALI, K. H., HAN, F. & MOHAMED, I. I., 2020. Automatic Detection Of Oil Palm Tree From Uav Images Based On The Deep Learning Method. *Applied Artificial Intelligence*, 35(1), Pp. 13-24.
- NAUTHIKA, T. A., SUPRAYOGI, A. & SUDARSONO, B., 2017. Identifikasi Dan Estimasi Tingkat Produktivitas Kelapa Sawit Menggunakan Teknologi Lidar (Studi Kasus : Air Upas, Kabupaten Ketapang). *Jurnal Geodesi Undip*, 6(4), Pp. 254-262.
- PRASVITA, D. S., SANTONI, M. M., WIRAWAN, R. & TRIHASTUTI, N., 2021. Klasifikasi Pohon Kelapa Sawit Pada Data Fusi Citra Lidar Dan Foto Udara Menggunakan Convolutional Neural Network. *Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika*, 06(02), Pp. 406-405.
- RAMASARI, F., F., NITA, S. & K., 2021. Penggunaan Metode You Only Look Once Dalam Penentu Pindah Tanaman Cabai Besar Ternotifikasi Telegram. *Elektron*, 13(2), Pp. 48-52.
- RIDHOVAN, A. & SUHARSO, A., 2022. Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum. *Jipi*, 7(1), Pp. 58-65.
- STEFANO, A., 2019. Pemanfaatan Gis (Geographic Information System) Untuk Memonitor. *Buletin Loupe*, 15(2), Pp. 8-17.
- SUGANDI, A. N. & HARTONO, B., 2022. Implementasi Pengolahan Citra Pada Quadcopter Untuk Deteksi Manusia Menggunakan Algoritma Yolo. *Prosiding 13th Industrial Research Workshop And National Seminar*, 13(1), Pp. 183-188.
- ULTAMI, D., FAZLINA, Y. D. & S., 2022. Automatic Palm Counting Menggunakan Citra Resolusi Spasial Tinggi. *Jurnal Ilmiah Mahasiswa Pertanian*, 7(2), Pp. 621-626.
- YARAK, K. ET AL., 2021. Oil Palm Tree Detection And Health Classification On High-Resolution Imagery Using Deep Learning. *Mdpi*, 11(183), Pp. 1 - 16.
- ZHENG, J., WU, W., YU, L. & FU, H., 2021. Coconut Trees Detection On The Tenarunga Using High-Resolution Satellite Images And Deep Learning. *Igarss*, Pp. 6512 - 6515.