

CONVOLUTIONAL NEURAL NETWORK DAN FASTER REGION CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI KUALITAS BIJI KOPI ARABIKA

Gede Ardi Pratama ¹, Eva Yulia Puspaningrum ², Hendra Maulana ³

^{1,2,3} Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur; Jalan Rungkut Madya No.1 Gunung Anyar, Surabaya, Indonesia

Received: 12 Juli 2024

Accepted: 31 Juli 2024

Published: 7 Agustus 2024

Keywords:

Klasifikasi biji kopi;

Faster R-CNN;

CNN VGG-16;

Region Proposal Network.

Correspondent Email:

evapuspaningrum.if@upnjatim.ac.id

Abstrak. Industri kopi global sangat dipengaruhi oleh peran masyarakat pecinta kopi, yang menciptakan ekosistem dimana kopi tetap menjadi komoditas istimewa. Salah satu aspek penting dalam pengelolaan kopi adalah penentuan grade kopi. Standar penilaian cacat pada biji kopi telah diakui secara nasional sejak tahun 1984 dan diperbarui dengan SNI 01-2907-2008 untuk memastikan kualitas dan konsistensi. Untuk meningkatkan efisiensi dan akurasi proses grading kopi, diperlukan sistem otomatis berbasis deep learning. Penelitian ini membahas penerapan CNN dan Faster R-CNN untuk klasifikasi biji kopi, dengan menggunakan biji kopi arabika, robusta, dan liberica. Algoritma CNN VGG-16 dan Faster R-CNN dibandingkan untuk mengidentifikasi pengaruh Region Proposal Network (RPN) terhadap efisiensi klasifikasi citra. Hasil penelitian menunjukkan bahwa CNN VGG-16 mencapai akurasi 86%, sementara Faster R-CNN mencapai rata-rata akurasi 93%, dengan presisi 93%, recall 92%, dan skor F1 92%. Penelitian ini bertujuan untuk memberikan pemahaman mendalam tentang kedua algoritma dalam konteks klasifikasi biji kopi serta meningkatkan efisiensi proses grading kopi.

Abstract. The global coffee industry is significantly influenced by the role of coffee enthusiasts, creating an ecosystem where coffee remains a premium commodity. One crucial aspect of coffee management is determining the coffee grade. The defect assessment standard for coffee beans has been nationally recognized since 1984 and was updated with SNI 01-2907-2008 to ensure quality and consistency. To enhance the efficiency and accuracy of the coffee grading process, an automated system based on deep learning is required. This study discusses the application of CNN and Faster R-CNN for coffee bean classification, utilizing arabica, robusta, and liberica beans. The CNN VGG-16 and Faster R-CNN algorithms are compared to identify the impact of the Region Proposal Network (RPN) on image classification efficiency. The results show that the CNN VGG-16 achieved an accuracy of 86%, while Faster R-CNN achieved an average accuracy of 93%, with a precision of 93%, recall of 92%, and an F1 score of 92%. This research aims to provide a comprehensive understanding of both algorithms in the context of coffee bean classification and to improve the efficiency of the coffee grading process.

1. PENDAHULUAN

Perkembangan industri kopi global sangat dipengaruhi oleh peran masyarakat pecinta kopi, yang menciptakan ekosistem dimana kopi tetap menjadi komoditas istimewa. Salah satu aspek penting dalam pengelolaan kopi adalah penentuan grade kopi. Sejak tahun 1984, penentuan grade kopi untuk standar mutu perdagangan telah didasarkan pada standar penilaian cacat pada biji kopi yang diakui secara nasional.

Penentuan grade kopi telah diperbarui dengan penerbitan SNI 01-2907-2008, menggantikan SNI 01-2907-1999 mengenai biji kopi. Tujuan dari proses sortir atau grading coffee adalah untuk mengklasifikasikan biji kopi sehingga tercipta kriteria kualitas yang menyeluruh dan memudahkan penetapan harga secara adil. Dalam penilaian cacat, semakin tinggi nilai cacat biji kopi, semakin rendah mutunya. Sebaliknya, semakin rendah nilai cacat, semakin tinggi mutu biji kopi.

Oleh karena itu dibutuhkan suatu sistem yang dapat menganalisa kualitas biji kopi untuk mempermudah industri kopi dalam melakukan grading coffee kedepannya, sehingga dapat memudahkan dalam menetapkan harga jual. Selain itu juga dapat membantu industri kopi terutama pada proses grading kopi yang awalnya dilakukan secara manual oleh ahli kopi dimana membutuhkan waktu dan biaya yang cukup besar, dengan deep learning dapat membantu meningkatkan efisiensi dan akurasi proses grading kopi. Proses grading kopi juga dilakukan secara otomatis sehingga dapat menghemat waktu dan biaya operasional. Menggunakan metode deep learning pada komputer membutuhkan berbagai macam teknik pengolahan citra dan computer vision. Biji kopi yang telah melalui proses penjemuran akan difoto menggunakan kamera untuk mendapatkan citra biji kopi. Selanjutnya citra biji kopi tersebut akan diproses menggunakan salah satu cabang teknik kecerdasan buatan, yaitu Machine Learning.

Sejumlah penelitian telah dilakukan, termasuk identifikasi kualitas biji kopi arabika berdasarkan cacat menggunakan teknik convolutional neural network (CNN). Hasil penelitian menunjukkan bahwa untuk model 2-kelas, akurasi terbaik yang dicapai adalah 82,46% dengan tingkat pembelajaran 0,0001. Sementara itu, model 4-kelas mencapai akurasi

tertinggi sebesar 70,73% dengan dua lapisan konvolusional. Algoritma Faster R-CNN juga mengintegrasikan arsitektur CNN seperti VGG-16 sebagai fitur ekstraktor. VGG-16 berfungsi untuk mengekstraksi fitur dari setiap kandidat kotak pembatas objek dalam kerangka kerja Faster R-CNN [1].

Penelitian terkait penerapan convolutional neural network dan transfer learning pada model VGG-16 dan MobileNetV2 untuk klasifikasi biji kopi. Dari hasil pengujian, akurasi CNN dengan model VGG16 dalam mengklasifikasikan dataset biji kopi mencapai 95% [2]. Berdasarkan jurnal acuan, dijelaskan bahwa program dengan metode Faster R-CNN mencapai kinerja terbaik menggunakan kecepatan pembelajaran 0,0001. Hasilnya menunjukkan rata-rata akurasi sebesar 94%, presisi 95%, recall 100%, dan skor F1 sebesar 97,2% untuk setiap kelas.

Penelitian terkait menunjukkan implementasi convolutional neural network dan transfer learning pada model VGG-16 dan MobileNetV2 untuk klasifikasi biji kopi. Hasil pengujian menunjukkan bahwa model VGG-16 mencapai akurasi 95% dalam klasifikasi dataset biji kopi. Berdasarkan jurnal acuan, metode Faster R-CNN memberikan kinerja optimal dengan kecepatan pembelajaran 0,0001, menghasilkan rata-rata akurasi 94%, presisi 95%, recall 100%, dan skor F1 sebesar 97,2% untuk setiap kelas [3].

Berdasarkan beberapa penelitian sebelumnya maka penelitian ini dilakukan untuk membandingkan algoritma Faster R-CNN dan CNN VGG-16 dalam klasifikasi biji kopi. Fokusnya adalah peran Region Proposal Network (RPN) dalam Faster R-CNN dan pengaruhnya terhadap efisiensi klasifikasi citra. Penelitian melibatkan biji kopi arabika, robusta, dan liberica yang umum dibudidayakan di Indonesia dan internasional. Dari penelitian sebelumnya, algoritma CNN VGG-16 mencapai akurasi 95%. Namun, studi ini juga mengevaluasi kinerja algoritma Faster R-CNN dengan akurasi rata-rata 94%, presisi 95%, recall 100%, dan Skor F1 97,2%. Penelitian ini akan memberikan pemahaman yang lebih mendalam tentang kedua algoritma dalam konteks klasifikasi biji kopi [4].

Atas dasar tersebut, penelitian ini akan menerapkan Convolutional Neural Network (CNN) dan Faster Region Convolutional Neural

Network (Faster R-CNN) untuk mengklasifikasikan kualitas biji kopi. Output dari penelitian ini adalah perbandingan kinerja antara Faster R-CNN dan CNN VGG-16, serta dampak Region Proposal Network (RPN) terhadap efisiensi klasifikasi citra. Tujuan penelitian ini adalah untuk memberikan pemahaman yang lebih mendalam tentang kedua pendekatan ini dalam konteks klasifikasi biji kopi, serta memperbaiki efisiensi dan akurasi proses grading kopi. Ini akan memberikan manfaat signifikan bagi industri kopi dalam menetapkan harga jual dan mengoptimalkan proses operasional.

2. TINJAUAN PUSTAKA

2.1. Pengertian Citra

Citra adalah representasi dari dunia nyata yang direkam oleh mesin atau alat elektronik [5]. Ada dua jenis citra yang dapat dibedakan, yaitu citra analog dan citra digital. Citra digital merupakan representasi citra dalam bentuk data numerik.

2.2. Deep Learning

Deep Learning adalah sebuah model jaringan syaraf tiruan yang saat ini tengah berkembang pesat dalam konteks pengenalan citra, didorong oleh kemajuan teknologi Graphic Processing Unit (GPU). Salah satu keunggulan utama dari Deep Learning adalah tingkat akurasi yang tinggi. Contoh konkret dari penerapan Deep Learning dalam pengenalan citra adalah Convolutional Neural Network (CNN), yang merupakan evolusi dari Multi Layer Perceptron (MLP) [6].

2.3. Klasifikasi

Klasifikasi adalah proses yang bertujuan untuk memprediksi kategori atau kelas dari data yang tidak dikenal. Untuk mencapai hal ini, dilakukan pembangunan model atau fungsi yang mampu membedakan kelas-kelas data tersebut. Setiap algoritma klasifikasi memiliki keunggulan dan kelemahan masing-masing, tetapi prinsipnya serupa, yaitu melakukan pelatihan menggunakan data yang sudah diketahui kelasnya [7].

2.4. Feature Learning

Feature learning berkembang karena keterbatasan feature engineering, di mana setiap

jenis data memerlukan pendekatan ekstraksi fitur yang berbeda. Hal ini membuat metode feature engineering kurang mampu menggeneralisasi pada berbagai jenis data seperti pada kasus klasifikasi objek dalam citra. Contoh dalam pengolahan data yang kompleks seperti citra dan suara, umumnya melibatkan ekstraksi fitur untuk mengubah data menjadi format yang dapat dipahami oleh algoritma pembelajaran [8].


2.5. Fully Connected Layer

Fully-Connected Layer adalah jenis lapisan di mana setiap neuron aktivasi dari lapisan sebelumnya terhubung langsung dengan setiap neuron di lapisan berikutnya. Perbedaan antara Fully Connected Layer dan lapisan konvolusi adalah bahwa neuron dalam lapisan konvolusi hanya terhubung dengan area tertentu dari input, sedangkan Fully Connected Layer memiliki setiap neuron yang terhubung secara keseluruhan [9].

2.6. Machine learning

Machine learning adalah salah satu cabang dari kecerdasan buatan (AI) yang memungkinkan mesin untuk belajar dari data dan melakukan tugas-tugas tertentu sesuai dengan apa yang dipelajari. Teknologi machine learning (ML) adalah mesin yang dikembangkan untuk bisa belajar dengan sendirinya tanpa arahan dari penggunaannya. Pembelajaran mesin dikembangkan berdasarkan disiplin ilmu lainnya seperti statistika, matematika dan data mining sehingga mesin dapat belajar dengan menganalisa data tanpa perlu di program ulang atau diperintah [10].

2.7. Convolutional Neural Networks




Gambar 1. Contoh arsitektur CNN

Convolutional Neural Networks (CNN) adalah salah satu jenis jaringan syaraf tiruan yang telah mengalami pertumbuhan pesat dalam beberapa tahun terakhir [8]. Berbeda dengan

Multi-Layer Perceptron (MLP), CNN memiliki struktur yang berbeda dan mampu mengatasi tugas klasifikasi citra dengan lebih efektif. Keunggulan utama CNN adalah kemampuannya untuk secara otomatis mempelajari fitur-fitur dari citra tanpa perlu proses ekstraksi fitur terpisah. Arsitektur CNN terdiri dari dua bagian utama, yaitu Feature Learning dan Classification, yang melibatkan lapisan-lapisan seperti convolution layer, activation function (ReLU), dan pooling. Pada tahap ekstraksi, CNN menggunakan beberapa hidden layer yang menjalankan fungsi konvolusi dan pooling. Sedangkan pada tahap klasifikasi, CNN menggunakan fully connected layer dan activation function (softmax) untuk menghasilkan output. Dalam penelitian ini, CNN menggunakan Rectified Units (RU) sebagai fungsi aktivasi pada tahap konvolusi dan pooling.

2.8. VGGNet

Arsitektur VGGNet ialah arsitektur pengembangan dari alexnet yang mana arsitektur tersebut fokus pada proses ekstraksi fitur di layer konvolusi sehingga mampu mendapatkan representasi citra yang banyak untuk dapat di klasifikasi. Arsitektur VGG-16 merupakan bagian dari model deep learning meliputi dari 16 layer [11]. Model arsitektur VGG-16 dapat dilihat pada Gambar 2. Sedangkan arsitektur VGG-16 sendiri memiliki 13 layer lapisan konvolusi, dan 2 lapisan digunakan sebagai fully_connected, serta 1 lapisan klasifikasi.



Gambar 2. Model arsitektur VGG-16

tiap susunan konvolusi diatas memiliki dimensi kernel 3x3. Perbedaannya pada tiap susunan konvolusi dari masing-masing susunan jumlah filter. Jumlah filter 64 ada pada dua susunan konvolusi awal, sedangkan jumlah kernel 128 susunan tiga serta empat. Begitu pada susunan konvolusi lain yang jumlah

filternya berbeda ialah 256 (susunan 4 5 6) serta 512 (susunan 7 8 9 10 11 12) [12]. 2x2 max pooling digunakan sesudah susunan konvolusi 2 4 7 10 serta 13. output pooling terakhir akan dihubungkan ke layer fully connected, dan pada akhirnya terhubung ke klasifikasi guna untuk penentuan class ataupun label dataset.

2.9. Faster R-CNN

Metode Faster R-CNN yang diusulkan dalam memiliki dua langkah utama: mengekstraksi dan melatih sekitar 200 region proposals menggunakan Region Proposal Network (RPN) dan mengklasifikasikannya berdasarkan fitur yang diperoleh [5]. Dalam proses pelatihan, terdapat empat tahap: melatih Region Proposal Network (RPN), melatih Jaringan Fast R-CNN menggunakan RPN dari langkah pertama, melatih ulang RPN dengan berbagi bobot dengan Fast R-CNN, dan melatih ulang Fast R-CNN menggunakan RPN yang telah diperbarui. RPN terdiri dari dua jaringan. Yang pertama adalah CNN. Lima lapisan terakhir dari CNN digantikan dengan lapisan konvolusi 3x3 yang diikuti oleh lapisan ReLU, lapisan 1x1 yang diikuti oleh lapisan Reshape untuk lapisan RPN, lapisan softmax, dan lapisan klasifikasi RPN. Jaringan kedua terdiri dari dua lapisan: lapisan konvolusi 1x1 untuk kotak regresi (RPN) dan Lapisan Output Regresi Kotak Smooth-L1. Proses pelatihan RPN bertujuan untuk meminimalkan fungsi kerugian total yang merupakan agregat dari fungsi kerugian data pada tahap klasifikasi dan fungsi kerugian regularisasi.

2.10. RPN

Untuk memperoleh region proposal, pada setiap lokasi jendela geser, sejumlah region proposal diekstraksi berdasarkan kotak referensi yang dikenal sebagai anchor. Anchor ini memiliki sembilan bentuk yang berbeda dengan tiga skala yang berbeda: 128, 256, dan 512, serta tiga perbandingan aspek yang berbeda, yaitu 1:1, 1:2, dan 2:1 untuk setiap skala [12]. Region proposal diekstraksi apabila nilai IoU (Intersection over Union) antara wilayah ground truth dan anchor lebih besar dari 0,7, yang menunjukkan bahwa ada objek yang terdapat pada anchor tersebut. Sebaliknya, jika nilai IoU kurang dari atau sama dengan 0,3, maka anchor tersebut dianggap bukan objek. IoU adalah ukuran perpotongan antara wilayah

yang terdeteksi (Rd) dan wilayah ground truth (RGT), serta gabungan dari dua wilayah tersebut dapat dirumuskan dalam persamaan 1 berikut:

$$IoU = \frac{Rd \cap RGT}{Rd \cup RGT}$$

2.11. Convolution Layer

Convolution Layer adalah langkah dalam pengolahan citra yang mengidentifikasi pola dalam citra input menggunakan kernel konvolusi. Konvolusi merujuk pada proses gabungan dua fungsi untuk menciptakan fungsi baru yang merepresentasikan informasi dari keduanya. Pada CNN, bobot di layer ini menentukan kernel konvolusi yang digunakan, yang belajar dari input untuk menyesuaikan representasi fitur pada data citra [13].

2.12. Subsampling Layer

Subsampling adalah proses mengurangi ukuran data citra. Dalam pengolahan citra, tujuan subsampling adalah meningkatkan invariansi posisi dari fitur-fitur yang diekstraksi. Dalam sebagian besar arsitektur Convolutional Neural Network (CNN), salah satu metode subsampling yang umum digunakan adalah max pooling. Penggunaan lapisan pooling dalam Convolutional Neural Network (CNN) bertujuan untuk mengurangi ukuran citra sehingga dapat digunakan untuk lapisan konvolusi dengan langkah (stride) yang sama [14].

2.13. Confusion Matriks


Performa suatu model dapat dilihat dari analisa evaluasinya menggunakan confusion marix melakukan perhitungan nilai akurasi, recall, precision dan f1-score dari sebuah model pembelajaran mesin [15]. Dalam melakukan perhitungan confusion matriks terdapat empat kondisi kasus yang perlu diperhatikan yaitu:

- True Positive (TP): Kondisi saat hasil prediksi benar dan realitanya memang benar.
- True Negative (TN): Kondisi saat hasil prediksi benar dan realitanya ternyata salah.
- False Positive (FP): Kondisi saat hasil prediksi salah dan realitanya ternyata benar.

False Negative (FN): Kondisi saat hasil prediksi salah dan realitanya memang salah.

3. METODE PENELITIAN

Pada saat melakukan penelitian, dilakukan serangkaian langkah kerja untuk membantu penulis menyelesaikan penelitian dengan baik. Langkah-langkah kerja ini bertujuan untuk menjawab rumusan masalah dan mencapai tujuan penelitian. Berikut adalah langkah-langkah kerja dan tahapan dalam melakukan penelitian ini:



Gambar 3. Diagram tahap penelitian

3.1. Pengumpulan Data


Data yang digunakan pada penelitian ini diambil dari website USK-Coffee tersedia pada <https://comvis.unsyiah.ac.id/usk-coffee/> yang berisi tentang macam – macam kualitas biji kopi dengan format .JPG, ukuran citra awal 256 x 256 piksel. Data tersebut bersifat publik dan terdiri dari 4 jenis data yaitu biji kopi peaberry, biji kopi Longberry, biji kopi Premium dan biji kopi cacat yang masing – masing jenis data terdapat 2000 citra yang kemudian total data yang akan diteliti berjumlah 8000 citra. Sebaran dataset dapat dilihat pada table 1.

Tabel 1. Sebaran Dataset Kualitas Biji Kopi

No	Kelas Citra	Jumlah Data
1.	Peaberry	2000
2.	Longberry	2000
3.	Premium	2000
4.	Cacat	2000

3.2. Praproses Data


Sebelum masuk ke dalam proses klasifikasi citra, seluruh data citra terlebih dahulu melewati tahap praproses data. Praproses data sendiri merupakan langkah di mana data akan diubah dan disesuaikan, agar fitur data dapat diinterpretasikan oleh algoritma pembelajaran mesin. Berikut adalah ilustrasi dari tahapan praproses data yang dilakukan:

**Gambar 4.** Tahapan praproses citra

3.3. Perancangan Algoritma CNN


Pada gambar 6 dibawah ini merupakan arsitektur VGG-16 pada algoritma CNN yang digunakan. Pada gambar tersebut, CNN

berperan sebagai pengekstrak fitur dari data citra sampai penerapan proses klasifikasi. Arsitektur VGG-16 yang akan digunakan terdiri dari 5 lapisan konvolusi dan 5 lapisan pooling.

**Gambar 6.** Algoritma CNN arsitektur VGG-16

Alur dimulai dengan citra dimasukkan, dimana citra tersebut merupakan citra yang diproses dari tahapan sebelumnya yaitu augmentasi data. Selanjutnya, citra akan masuk ke lapisan konvolusi, setelah itu dilanjutkan ke dalam fungsi aktivasi ReLU. Fungsi aktivasi ReLU digunakan karena dataset berupa citra, dan fungsi aktivasi terbaik adalah menggunakan ReLU agar mendapat nilai fitur yang dapat mempresentasikan data dengan baik.

3.5. Perancangan Algoritma Faster R-CNN

**Gambar 7.** Algoritma Faster R-CNN

Pada Gambar 7 dijelaskan alur proses perancangan algoritma Faster R-CNN. Alur

dimulai dengan citra dimasukkan, dimana citra masukan tersebut merupakan citra yang telah diproses dari tahapan sebelumnya yaitu augmentasi data. Selanjutnya, citra akan diproses ke dalam lapisan CNN untuk mengambil frame yang memiliki fitur penting dan menghasilkan output berupa frame yang sudah diambil fitur pentingnya. CNN yang digunakan dalam Faster R-CNN adalah VGG-16 dimana terdiri dari beberapa proses konvolusi yang terdapat beberapa convolution masks yang berbeda-beda.

3.6. Perancangan Algoritma CNN

Pada tahap pelatihan model, data latih yang sudah melewati praproses data akan diproses dalam algoritma CNN dengan arsitektur VGG-16 dan algoritma Faster R-CNN. Sebelum itu, harus dilakukan inisialisasi parameter yang dibutuhkan untuk pelatihan seperti Loss, Metrik, Epochs, dan Batch Size. Kemudian, hasil dari pelatihan ini berupa model algoritma CNN dan Faster R-CNN yang terlatih. Untuk beberapa parameter dalam model compile yang digunakan akan dijelaskan pada Tabel 2.

Tabel 2. Parameter Compile Model

No	Jenis Parameter	Nilai Parameter
1.	Loss	Categorical Crossentropy
2.	Metrik	Akurasi
3.	Epochs	10
4.	Batch Size	32

4. HASIL DAN PEMBAHASAN

Penelitian mengenai CNN VGG-16 dan Faster R-CNN dalam klasifikasi kualitas biji kopi dilakukan dengan menggunakan optimizer ADAM dan RMSprop, jumlah epoch 10, *Learning Rate* 0.001% dan 0.0001%. Hal ini dilakukan agar nantinya rumusan masalah dapat terjawab mengenai akurasi Faster R-CNN dibandingkan akurasi CNN arsitektur VGG-16. Hasil dari proses pelatihan dan pengujian citra biji kopi diperoleh nilai accuracy dan loss sebagai berikut.

4.1. Hasil Pengujian Algoritma CNN VGG-

16



Gambar 1. Visualisasi Metriks Pelatihan

Pada Gambar 8 merupakan hasil visualisasi matriks pelatihan dimana pada proses pelatihannya dilakukan dengan cara memanfaatkan library matplotlib untuk visualisasi metrik pelatihan. Sumbu x menggunakan jumlah epoch, sedangkan sumbu y menampilkan akurasi dan loss. Terdapat dua plot yang menampilkan performa model pada data latih dan data validasi. Untuk menyesuaikan perbedaan loss, sumbu y pada plot loss diatur ke skala logaritmik. Hasil visualisasi disimpan dalam format PNG dan juga ditampilkan.

Proses pengujian model CNN VGG-16 yang telah dilatih untuk mengklasifikasikan biji kopi arabika ke dalam empat kategori: biji kopi cacat, biji kopi longberry, biji kopi peaberry, dan biji kopi premium. Pertama, model yang telah dilatih dimuat dari path yang ditentukan. Selanjutnya, lapisan fully connected dengan jumlah neuron sesuai jumlah kelas ditambahkan di atas model VGG-16. Hasil prediksi ditampilkan bersamaan dengan gambar asli. Fungsi ini juga mencetak kelas aktual dan hasil prediksi kelas biji kopi berdasarkan gambar yang diberikan. Contoh hasil prediksi dapat dilihat pada Gambar 9.




Gambar 9. Hasil Prediksi

Tabel 3. Evaluasi Matriks


	Precision	Recall	F1-Score	Support
Biji Premium	0.84	0.84	0.84	400
Biji Longberry	0.80	0.67	0.73	400
Biji Peaberry	0.84	0.96	0.89	400
Biji Cacat	0.98	0,98	0.98	400
Accuracy			0.86	1600
Macro avg.	0.87	0.86	0.86	1600
Weighted avg.	0.86	0.86	0.86	1600

Pada Tabel 3 dapat dilihat *classification report* dari CNN arsitektur VGG-16 yang mendapat akurasi 86%. Selain itu, tingkat *precision* tertinggi didapat pada kelas biji kopi cacat dengan hasil 98%.


**Gambar 10.** Hasil Confusion Matrix CNN VGG-16

Pada Gambar 10 dapat dilihat *confusion matrix* dari skenario CNN arsitektur VGG-16 terbaik.

4.2. Hasil Pengujian Algoritma Faster R-CNN

**Gambar 11.** Kurva Pelatihan Faster R-CNN

Pada gambar 11 merupakan visualisasi riwayat pelatihan model melalui grafik akurasi dan loss memanfaatkan library matplotlib. Pertama, riwayat pelatihan diperoleh dari objek model yang berisi data akurasi dan loss untuk setiap epoch. Jumlah epoch ditentukan berdasarkan panjang data akurasi dalam riwayat pelatihan. Kode ini kemudian membuat dua subplot dalam satu figure: yang pertama menampilkan grafik akurasi pelatihan dan validasi terhadap jumlah epoch, dan yang kedua menampilkan grafik loss pelatihan dan validasi terhadap jumlah epoch, dengan skala logaritmik pada sumbu y untuk memberikan pandangan yang lebih jelas terhadap perubahan nilai loss.

**Gambar 12.** Confusion Matrix Faster R-CNN

Hasil *confusion matrix* selanjutnya adalah hasil dari skenario terbaik Faster R-CNN yang dapat dilihat pada Gambar 12.

Tabel 4. Evaluasi Matriks

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Biji Premium	0.89	0.94	0.91	400
Biji Longberry	0.91	0.82	0.86	400
Biji Peaberry	0.91	0.96	0.94	400
Biji Cacat	1.00	0,98	0.99	400
Accuracy			0.93	1600
Macro avg.	0.93	0.92	0.92	1600
Weighted avg.	0.86	0.86	0.86	1600

Pada Tabel 4 dapat dilihat classification report dari Faster R-CNN yang mendapat akurasi 93%. Selain itu, tingkat precision tertinggi didapat pada kelas biji kopi cacat dengan hasil 100%. Selain itu, berdasarkan classification report yang ada nilai support yang dimiliki dari masing-masing skenario metode memiliki jumlah persebaran data yang sama.

4.3. Evaluasi Akhir

Setelah menampilkan hasil evaluasi dari skenario terbaik yang ada menggunakan confusion matrix dan classification report, langkah terakhir adalah melakukan evaluasi akhir untuk menentukan metode yang memiliki tingkat akurasi tertinggi. Hasil tingkat akurasi tertinggi dari tiap skenario terbaik dapat dilihat pada tabel 5.

Tabel 4. 1 Akurasi Skenario Terbaik

No.	Metode	Akurasi
1.	CNN VGG-16	86%
2.	Faster R-CNN	93%

5. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa perbandingan antara algoritma Convolutional Neural Network VGG-16 dan Faster R-CNN dalam klasifikasi kualitas biji kopi arabika adalah sebagai berikut:

- Evaluasi Performa CNN-VGG16 dan Faster R-CNN dilakukan menggunakan confusion matrix dan classification report dengan hasil tingkat tara-rata akurasi metode CNN-VGG16 adalah sebesar 93%. Sedangkan Rata-rata akurasi Faster R-CNN sebesar 86%.
- Faster R-CNN memperoleh hasil tertinggi dikarenakan kemampuan dari RPN mampu menangkap fitur-fitur secara komprehensif dan model yang dibangun lebih kokoh dibandingkan model CNN-VGG16.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Tuhan Yang Maha Esa atas limpahan kekuatan serta kepaahaman terhadap ilmu yang diberikan kepada penulis hingga saat ini, kepada orang tua serta kepada pihak yang ikut serta berperan dalam memberi dukungan dalam pengerjaan penelitian ini.

DAFTAR PUSTAKA

- [1] J. Pardede And H. Hardiansah, "Deteksi Objek Kereta Api Menggunakan Metode," *Mind (Multimedia Artificial Intelligent Networking Database) Journal*, Pp. 21-36, 2022.
- [2] M. Murinto, M. Rosyda And M. Melany, "Klasifikasi Jenis Biji Kopi Menggunakan Convolutional Neural Network Dan Transfer Learning Pada Model Vgg16 Dan

- Mobilenetv2,” *Jrst: Jurnal Riset Sains Dan Teknologi*, Vol. 7, No. 2, Pp. 183-189, 2023.
- [3] N. Gilbert and A. Rusli, “Single object detection to support requirements,” pp. 830-838, April 2020.
- [4] D. L. Fajri, “9 Jenis Kopi Populer di Indonesia,” 9 September 2022. [Online]. Available: <https://katadata.co.id/intan/berita/620367a42faec/9-jenis-kopi-populer-di-indonesia>.
- [5] N. Ibrahim, G. A. L. F. S. Hanafi, K. Saleh, N. K. C. Pratiwi, M. S. Haq And A. I. Mastur, “Klasifikasi Tingkat Kematangan Pucuk Daun Teh Menggunakan Metode Convolutional Neural Network,” *Elmonika: Jurnal Teknik Energi Elektrik. Teknik Telekomunikasi, & Teknik Elektronika*, Vol. 06, Pp. 162 - 176, 2021.
- [6] T. Zhou, S. Ruan And S. Canu, “A Review: Deep Learning For Medical Image Segmentation Using Multi-Modality Fusion,” *Cornell University*, P. 2020, 22 April 2020.
- [7] Dahniyal, “Implementation Of K-Means Clustering Method To Lecturers Based On Publications Of National Journals And Accredited Sinta,” *Journal Of Electrical Engineering And Computer Sciences*, Vol. 8, Pp. 27-38, 2023.
- [8] Frangky Handono, “Implementasi Convolutional Neural Network (Cnn) Untuk Deteksi Retinopati Diabetik,” *Jurnal Informatika Dan Sistem Informasi*, Vol. 1, No. 1, Pp. 669-678, 2020.
- [9] R. N. Auliasari, L. Novamizanti And N. Ibrahim, “Identifikasi Kematangan Daun Teh Berbasis Fitur Warna Hue Saturation Intensity (Hsi) Dan Hue Saturation Value (Hsv),” *Jurnal Informatika (Juita)*, Vol. 8, No. 2, Pp. 2017-2020, 2020.
- [10] R. R. Karim And A. Herlangga, “Implementasi Klasifikasi Senjata Tradisional Jawa Barat Menggunakan Convolutional Neural Network (Cnn) Dengan Metode Transfer Learning,” *Jitet (Jurnal Informatika Dan Teknik Elektro Terapan)*, Vol. 12, P. 1211, 2024.
- [11] M. Saputra, K. Kusri And M. P. Kurniawan, “Identifikasi Mutu Biji Kopi Arabika Berdasarkan Cacat Dengan Teknik Convolutional Neural Network,” *Inspiration: Jurnal Teknologi Informasi Dan Komunikasi*, Pp. 27-34, 2020.
- [12] Honainah, “Penerapan Metode Faster Region Convolutional Neural Network,” *Nusantara Journal Of Computers And Its Application (NJCA)*, Pp. 9-18, 2022.
- [13] A. Peryanto, A. Yudhana and R. Umar, “Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network,” *Jurnal Ilmiah Teknik Informatika (FORMAT)*, vol. 8, pp. 139-140, 2019.
- [14] K. Prayoga, R. Magdalena and S. Saidah, “Sistem Deteksi Kecacatan Ban Dengan Convolutional Neural Network,” *e-Proceeding of Engineering*, vol. 10, 2023.
- [15] V. Atliha and D. Šešok, “Comparison of VGG and ResNet used as Encoders for Image Captioning,” *2020 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream)*, pp. 1-4, 2020.