

Perbandingan Kinerja Arsitektur LeNet-5 dan AlexNet dalam Klasifikasi Daun Teh Siap Panen Menggunakan Convolutional Neural Network

Performance Comparison of LeNet-5 and AlexNet Architectures in Classifying Ready-to-Harvest Tea Leaves Using Convolutional Neural Network (CNN)

Yusran Timur Samuel^{a*}, Juwita Rundengan^b

Universitas Advent Indonesia^{a,b}

^ay.tarihoran@unai.edu, ^b22081019@unai.edu

Abstract

The tea industry plays an important role in Indonesia's agribusiness sector, with the quality of tea being highly influenced by the selection of the right leaves and the appropriate timing of harvesting. The classification of tea leaves is still performed manually, relying on farmers' experience and potentially affected by external factors such as fatigue. This study aims to compare the performance of two Convolutional Neural Network (CNN) architectures, namely LeNet-5 and AlexNet, in classifying tea leaves as either ready for harvest or not yet ready based on metrics including accuracy, precision, recall, F1-score, loss, and computational efficiency. The dataset used in this study consists of 4,198 labeled images of tea leaves. The LeNet-5 and AlexNet models were trained and tested using this dataset, and the evaluation results revealed significant performance differences between the two architectures. The AlexNet model achieved an accuracy of 83.33%, with a precision of 0.86, recall of 0.90, and F1-score of 0.88 for the "Not Ready for Harvest" class, and a precision of 0.76, recall of 0.69, and F1-score of 0.72 for the "Ready for Harvest" class. Meanwhile, the LeNet-5 model reached an accuracy of 71.67%, with a precision of 0.75, recall of 0.88, and F1-score of 0.81 for the "Not Ready for Harvest" class, but only achieved a precision of 0.59, recall of 0.36, and F1-score of 0.45 for the "Ready for Harvest" class. Although LeNet-5 is more efficient in terms of processing time, AlexNet outperforms it in terms of accuracy and the ability to capture more complex patterns in tea leaf data. Both models exhibited signs of overfitting, but overall, AlexNet proved to be more effective for tea leaf harvest readiness classification. This study concludes that AlexNet is more optimal for classifying tea leaves with higher accuracy and better performance compared to LeNet-5, although it requires greater computational resources.

Keywords: Tea leaf classification, Convolutional Neural Network, LeNet-5, AlexNet

Abstrak

Industri teh memiliki peran penting dalam sektor agribisnis Indonesia, dengan kualitas teh yang sangat dipengaruhi oleh pemilihan daun yang tepat dan waktu pemetikan yang sesuai. Klasifikasi daun teh masih dilakukan secara manual, yang mengandalkan pengalaman petani dan dapat dipengaruhi oleh faktor eksternal seperti kelelahan. Penelitian ini bertujuan untuk membandingkan kinerja dua arsitektur Convolutional Neural Network (CNN), yaitu LeNet-5 dan AlexNet, dalam mengklasifikasikan daun teh siap panen dan belum siap panen berdasarkan metrik akurasi, presisi, recall, F1-score, loss, serta efisiensi komputasi. Dataset yang digunakan dalam penelitian ini terdiri dari 4.198 gambar daun teh yang telah dilabeli. Model LeNet-5 dan AlexNet dilatih dan diuji menggunakan dataset ini, dan hasil evaluasi menunjukkan perbedaan performa yang signifikan antara keduanya. Model AlexNet menghasilkan akurasi 83,33%, dengan precision 0,86, recall 0,90, dan F1-score 0,88 untuk kelas "Belum Siap Panen", serta precision 0,76, recall 0,69, dan F1-score 0,72 untuk kelas "Siap Panen". Sementara itu, model LeNet-5 mencapai akurasi 71,67%, dengan precision 0,75, recall 0,88, dan F1-score 0,81 untuk kelas "Belum Siap Panen", namun hanya memperoleh precision 0,59, recall 0,36, dan F1-score 0,45 untuk kelas "Siap Panen". Meski LeNet-5 lebih efisien dalam hal waktu pemrosesan, AlexNet lebih unggul dalam akurasi dan kemampuan menangkap pola yang lebih kompleks pada data daun teh. Kedua model menunjukkan gejala overfitting, tetapi secara keseluruhan AlexNet lebih efektif untuk klasifikasi daun teh siap panen. Penelitian ini menyimpulkan bahwa AlexNet lebih optimal dalam mengklasifikasikan daun teh dengan akurasi dan kinerja yang lebih baik dibandingkan dengan LeNet-5, meskipun membutuhkan sumber daya komputasi yang lebih besar.

Kata Kunci: Klasifikasi daun teh, Convolutional Neural Network, LeNet-5, AlexNet

1. Pendahuluan

Industri teh memiliki peran penting dalam sektor agribisnis di Indonesia, sebagai salah satu produsen teh terbesar di dunia, Indonesia memiliki perkebunan teh yang cukup luas. Berdasarkan data (Indonesia-Investment, 2024; Isnur. Putri, 2024) yang dikutip dari BPS, Pada 2022, luas perkebunan teh mencapai 101.281 hektare

dengan produksi 124.662 ton, sementara pada 2023 luasnya menurun menjadi 97.564 hektare dengan produksi 116.507 ton. Jawa Barat menjadi daerah penghasil teh terbesar. Meskipun lahan petani kecil berkurang, produktivitas mereka meningkat. Rata-rata produktivitas teh nasional mencapai 1.800 kg/hektare, dengan petani kecil menghasilkan sekitar 950 kg/hektare. Sebagian besar teh Indonesia diekspor ke mancanegara, dengan 56 negara tujuan pada 2023. Daun teh dihasilkan dari tanaman *Camellia Sinensis*, di mana kualitas teh seduhan bergantung pada pemilihan daun yang tepat dan waktu pemetikan yang sesuai. Pemanenan menjadi tahap penting karena hanya daun dengan kematangan tertentu yang layak dipetik, yang memengaruhi rasa, aroma, dan mutu teh (Ferdiansyah & Zamzami, 2022; Prastiwi & Lontoh, 2019). Teh dengan kualitas rendah, nantinya akan menghasilkan rasa yang kurang enak, bahkan cenderung pahit atau astringent. Selama ini, klasifikasi daun teh masih dilakukan secara manual berdasarkan pengalaman petani, yang bergantung pada subjektivitas dan keahlian, serta dipengaruhi faktor lingkungan seperti cuaca dan kelelahan pekerja. Oleh karena itu, dibutuhkan sistem berbasis teknologi yang dapat menggantikan metode manual dengan solusi yang lebih akurat dan objektif. Kehadiran sistem ini diharapkan meningkatkan akurasi, efisiensi, dan konsistensi dalam pemilihan daun teh siap panen, sehingga kualitas teh tetap optimal (Ferdiansyah & Zamzami, 2022).

Kemajuan teknologi informasi dan komunikasi telah memengaruhi berbagai sektor, termasuk pertanian dan perkebunan, melalui penerapan machine learning, khususnya Convolutional Neural Network (CNN). CNN efektif dalam mengenali pola pada citra, seperti dalam membedakan berbagai jenis tanaman (Arrofiqoh & Harintaka, 2018) dan dalam klasifikasi penyakit daun teh dengan akurasi 79,36% (Ernawati, 2024). Dengan memanfaatkan teknologi CNN, proses seleksi daun teh siap panen dapat dilakukan lebih akurat, cepat, dan konsisten, serta mengurangi beban kerja petani. Dalam penelitian ini, dua arsitektur CNN yang populer, LeNet-5 dan AlexNet, akan dibandingkan. LeNet-5, dengan arsitektur sederhana, lebih cepat dalam pelatihan tetapi kurang efektif untuk dataset besar, sementara AlexNet lebih kompleks, mampu menangkap fitur lebih mendetail, tetapi memerlukan lebih banyak sumber daya dan waktu pelatihan (Al Rivan & Riyadi, 2021). Pengujian kedua arsitektur ini dilakukan untuk menentukan model yang lebih unggul dalam klasifikasi daun teh siap panen, berdasarkan akurasi, efisiensi komputasi, dan loss.

Peneliti akan menggunakan dataset citra daun teh yang telah dikumpulkan dan diklasifikasikan sebelumnya. Dataset tersebut nantinya akan peneliti gunakan untuk melatih dan menguji kedua arsitektur CNN, yaitu LeNet-5 dan AlexNet. Daun teh yang diklasifikasikan akan dibagi menjadi dua kelas, yaitu daun yang siap panen dan daun yang belum siap panen. Dimana, daun yang siap panen adalah daun dengan kualitas terbaik, yang memiliki ukuran yang pas, warna hijau cerah, dan tanpa cacat atau kerusakan. Kualitas daun teh ini sangat berpengaruh pada rasa teh yang dihasilkan. Teh yang dihasilkan dari daun yang tidak sesuai dengan standar kualitas akan menghasilkan cita rasa yang tidak optimal, bahkan bisa merusak keseluruhan pengalaman konsumsi teh (Maska, 2022). Fokus utama penelitian ini adalah untuk menentukan apakah daun teh yang di uji termasuk kategori siap panen atau belum siap panen, serta menguji ketiga aspek untuk kinerja model dilihat dari akurasi, presisi, recall, f1 score, dan hasil confusion matriks dalam mengidentifikasi daun teh yang siap dipanen. Kedua yaitu efisiensi komputasi yang dibutuhkan oleh masing-masing model, yang meliputi waktu pelatihan dan inference, serta penggunaan sumber daya


komputasi. Ketiga, loss atau tingkat kesalahan selama proses pelatihan, yang menunjukkan seberapa baik model dapat mempelajari pola dan fitur dari data yang digunakan. Nilai loss yang rendah menunjukkan bahwa model mampu memprediksi dengan akurasi tinggi dan kesalahan minimal (Bismi & Harafani, 2022).

Aspek-aspek tersebut nantinya akan peneliti analisa, sehingga dapat memberikan gambaran yang jelas tentang kelebihan dan kekurangan masing-masing arsitektur. Beberapa penelitian sebelumnya telah membahas perbandingan arsitektur LeNet-5 dan AlexNet. Misalnya, penelitian (Al Rivan & Riyadi, 2021) menunjukkan akurasi 91,62% untuk AlexNet dan 92,47% untuk LeNet-5 dalam pengenalan American Sign Language. Selain itu, penelitian lain oleh (Tarisa & Ariany, 2024) yang menunjukkan bahwa arsitektur AlexNet lebih unggul dibandingkan LeNet dalam klasifikasi citra anggrek, dengan akurasi masing-masing 79,50% dan 62,50%. Namun, hingga saat ini masih belum adanya penelitian yang membahas perbandingan kedua arsitektur tersebut dalam klasifikasi daun teh siap panen. Oleh karena itu, penelitian ini tetap relevan dan diperlukan, mengingat pentingnya penerapan teknologi machine learning secara langsung di sektor pertanian, khususnya dalam proses pemanenan daun teh.

Berdasarkan latar belakang yang telah penulis sajikan, rumusan masalah dalam penelitian ini meliputi beberapa aspek utama. Pertama, bagaimana kinerja LeNet-5 dalam mengklasifikasikan daun teh siap panen berdasarkan hasil akurasi, presisi, recall, f1-score, dan loss yang dihasilkan?. Kedua, bagaimana kinerja AlexNet dalam klasifikasi daun teh siap panen dengan parameter yang sama. Ketiga, bagaimana perbandingan kinerja antara arsitektur LeNet-5 dan AlexNet dalam memengaruhi hasil klasifikasi citra daun teh siap panen. Dengan demikian, tujuan dari penelitian ini adalah menganalisis kinerja LeNet-5 dalam mengklasifikasikan daun teh siap panen berdasarkan akurasi, presisi, recall, f1-score, dan loss yang dihasilkan, serta mengevaluasi kinerja AlexNet dengan parameter yang sama. Selain itu, penelitian ini bertujuan untuk mengevaluasi pengaruh perbedaan arsitektur LeNet-5 dan AlexNet terhadap kemampuan klasifikasi daun teh siap panen.

2. Metode


Penelitian ini akan berfokus membandingkan kinerja arsitektur LeNet-5 dan AlexNet dalam klasifikasi daun teh siap panen menggunakan Convolutional Neural Network (CNN), dimana langkah Langkah dalam penelitian in akan penulis sajikan dalam diagram alir pada gambar 1.



Gambar 1. Flowchart Penelitian

Pengumpulan Data

Penulis mengumpulkan data melalui studi literatur tentang kinerja LeNet-5 dan AlexNet dalam klasifikasi daun teh siap panen menggunakan CNN. Sumber-sumber ilmiah seperti jurnal, buku, dan skripsi digunakan untuk memperkaya landasan teori dan memahami tantangan dalam klasifikasi citra dengan CNN. Setelah itu, peneliti mencari dataset open-source sebanyak 5740 gambar yang berasal dari roboflow (Roboflow, 2023).




Gambar 2. Sampel Dataset Penelitian (Sebelum Re-Labeling)

Semua dataset yang diperoleh dari *platform roboflow* disajikan dalam bentuk citra, yang akan digunakan sebagai input dalam sistem CNN untuk klasifikasi daun teh berkualitas berdasarkan hasil tekstur, bentuk, dan warna daun sehingga memperoleh keluaran informasi mengenai daun siap panen (penampilan segar dengan warna hijau cerah dan permukaan mengkilap) dan belum siap panen ditandai dengan hijau pucat, tekstur kasar dan daun yang terlalu besar.

Labeling dan Input Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dengan langsung menyambungkan API dari proyek Roboflow, tanpa perlu proses pengunduhan manual. Dataset tersebut sudah terdiri dari citra daun teh beserta label awalnya yang terbagi menjadi empat kelas, yaitu 0, 1, 2, dan 3. Namun, dalam penelitian ini dilakukan proses relabeling terhadap label-label tersebut untuk menyesuaikannya dengan kebutuhan klasifikasi. Kelas 0 dihapus karena tidak relevan dengan fokus penelitian. Kelas 1 direlabel sebagai "daun teh siap panen", sementara kelas 2 dan 3 digabung dan direlabel menjadi "daun teh belum siap panen". Proses relabeling ini didasarkan pada tingkat kematangan daun teh yang tampak pada citra, di mana daun muda dikategorikan sebagai siap panen dan daun yang lebih tua dikategorikan sebagai belum siap panen. Terlihat pada Gambar 3 labeling pada Roboflow yang mulanya 1, penulis relabeling ke Siap Panen dikarenakan daun terlihat mengkilap, berwarna hijau cerah, dan memiliki tekstur yang lembut—ciri khas dari daun teh muda yang ideal untuk dipanen.


20231226_142243.jpg.rf.e259b69647ee6fb0cf677667dd4f9b3a - Notepad
File Edit Format View Help
1 0.4875 0.746875 0.3515625 0.50625



Gambar 3. Label Roboflow Kelas 1; b. Citra Kelas 1


Begitupun kelas 2 dan 3 yang dapat dilihat pada Gambar 4 dan 5, di mana labeling pada Roboflow mulanya berlabel 2 dan 3, yang selanjutnya penulis relabeling ke Belum Siap Panen dikarenakan daun terlihat tua, berwarna hijau gelap, kusam, dan memiliki tekstur yang lebih kasar—menunjukkan bahwa daun tersebut telah melewati fase kematangan optimal untuk dipanen.

*IMG_20231226_121834.jpg.rf.5b4fed61f2638e670aaf4f3c90c27928 - Notepad
File Edit Format View Help
2 0.45234375 0.5265625 0.7515625 0.50078125



Gambar 4. Label Roboflow Kelas 2; b. Citra Kelas 2

IMG_20231226_151122.jpg.rf.4203465c27a10a8c5621accab89a3727 - Notepad
File Edit Format View Help
3 0.5078125 0.434375 0.4421875 0.6546875



Gambar 5. Label Roboflow Kelas 2; b. Citra Kelas 3

Setelah proses relabeling selesai, seluruh dataset yang telah diproses dikompresi menjadi satu file arsip dengan nama data_asli.zip yang terletak di direktori /content/Tea-Leaves-Dataset-2. File data_asli.zip berhasil dibuat, dan selanjutnya, proses dilanjutkan dengan mencoba mengunduh file ZIP tersebut yang menghasilkan relabeling duan siap panen dan belum siap panen.



Gambar 6. Hasil Folder Setelah Proses Relabeling

Pra-Processing Data

Pada tahap pra-processing data, dilakukan langkah-langkah dengan mere-size, normalisasi data, dan augmentasi data. Re-size bertujuan menyamakan ukuran gambar untuk memudahkan pemrosesan. Normalisasi data mengubah nilai pixel gambar ke rentang seragam agar model lebih cepat dan akurat. Augmentasi data menambah jumlah dan keragaman data pelatihan dengan teknik seperti rotasi, pemotongan, atau flipping, membuat model lebih fleksibel. Semua tahapan pra-processing ini disesuaikan gambar dimulai dengan resize, di mana gambar diubah ukurannya menjadi 32×32 piksel untuk LeNet-5 dan 227×227 piksel untuk AlexNet, menyesuaikan kebutuhan input arsitektur masing-masing. Selanjutnya, gambar dikonversi ke grayscale (1 channel) untuk LeNet-5 untuk mengurangi kompleksitas data, sementara untuk AlexNet, gambar tetap dalam format RGB (3 channel) untuk mempertahankan informasi warna yang penting dalam deteksi fitur. Proses normalisasi dilakukan pada kedua model, dengan piksel gambar dinormalisasi ke skala 0–1 atau -1 hingga 1 untuk mempercepat konvergensi dan meningkatkan stabilitas pelatihan. Terakhir, pada tahap augmentasi data, berbagai teknik diterapkan, termasuk rotasi gambar $\pm 10^\circ$, flipping horizontal dan vertikal, variasi pencahayaan $\pm 20\%$, serta penambahan noise Gaussian untuk meningkatkan variasi data pelatihan, mengurangi overfitting, dan memperbaiki generalisasi model.



Gambar 7. Hasil unduhan file tahapan relabeling dan pre-processing pada test alexnet siap panen

Implementasi Model

Dataset yang telah dipra-pemrosesan selanjutnya digunakan untuk pembuatan model dengan Convolutional Neural Network (CNN), menerapkan dua arsitektur populer, LeNet-5 dan AlexNet. LeNet-5, dengan struktur sederhana, efektif untuk pengenalan pola dan klasifikasi gambar kompleksitas rendah, sementara AlexNet lebih kompleks dan cocok untuk dataset dengan dimensi serta kerumitan tinggi. Pembuatan arsitektur ini mencakup pengaturan parameter penting seperti jumlah filter, ukuran kernel, fungsi aktivasi, ukuran feature map, stride, dan jumlah output kelas, yang memengaruhi akurasi dan efisiensi model. Setiap parameter, seperti filter dan kernel, menentukan kemampuan model mengekstraksi fitur, sementara fungsi aktivasi seperti ReLU memperkenalkan non-linearitas, dan stride mengatur pergeseran kernel. Parameter ini akan disajikan dalam tabel untuk memudahkan pemahaman, dimulai dengan arsitektur LeNet-5.

Tabel 2 Arsitektur LeNet-5

No	Layer	Atribut Input	Jumlah Filter	Ukuran Kernel	Stride	Activation Function	Ukuran Feature Map	Output Kelas
1	Input Layer	Gambar grayscale 32×32×1	-	-	-	-	32×32×1	-
2	Convolutional	-	6	5×5	1	ReLU	28×28×6	-
3	Pooling	-	-	2×2	2	-	14×14×6	-
4	Convolutional	-	16	5×5	1	ReLU	10×10×16	-
5	Pooling	-	-	2×2	2	-	5×5×16	-
6	Fully Connected	-	-	-	-	ReLU	120	-
7	Fully Connected	-	-	-	-	ReLU	84	-
8	Output Layer	-	-	-	-	Softmax	2	Siap Panen/Belum Panen

Selanjutnya, Tabel 3 akan menunjukkan parameter untuk arsitektur AlexNet.

Tabel 3 Arsitektur Alexnet

No	Layer	Atribut Input	Jumlah Filter	Ukuran Kernel	Stride	Activation Function	Ukuran Feature Map	Output Kelas
1	Input Layer	Gambar RGB 227×227×3	-	-	-	-	227×227×3	-
2	Convolutional	-	96	11×11	4	ReLU	55×55×96	-
3	Pooling	-	-	3×3	2	-	27×27×96	-
4	Convolutional	-	256	5×5	1	ReLU	27×27×256	-
5	Pooling	-	-	3×3	2	-	13×13×256	-
6	Convolutional	-	a) 384	3×3	1	ReLU	13×13×384	-
7	Convolutional	-	b) 384	3×3	1	ReLU	13×13×384	-
8	Convolutional	-	c) 256	3×3	1	ReLU	13×13×256	-
9	Pooling	-	d) -	3×3	2	-	6×6×256	-
10	Fully Connected	-	e) -	-	-	ReLU	4096	-
11	Fully Connected	-	f) -	-	-	ReLU	4096	-
12	Output Layer	-	g) -	-	-	Softmax	2	Siap Panen/Belum Panen

Parameter model ini disesuaikan untuk mengidentifikasi daun teh siap panen berdasarkan warna hijau cerah dan permukaan mengkilap, sementara daun yang belum siap panen memiliki warna hijau pucat.

Data Processing

Proses pembuatan model dimulai dengan membagi dataset menjadi data training (80%) dan data testing (20%). Data training digunakan untuk melatih model mengenali pola klasifikasi daun teh, sementara data testing digunakan untuk mengevaluasi performa model pada data yang belum pernah dilihat. Pada tahap awal, hyperparameter default digunakan, seperti Optimizer Adam, Loss Function Cross-Entropy, Learning Rate 0.001, Batch Size 32, dan Epochs 50. Penyesuaian batch size dan epoch dilakukan untuk mencapai keseimbangan antara overfitting dan underfitting. Data training yang beragam membantu model mengenali berbagai karakteristik daun teh, sedangkan data testing mengevaluasi kemampuan model dalam mengklasifikasikan daun teh berdasarkan parameter seperti warna, ukuran, dan tekstur.

Evaluasi Kinerja Model

Evaluasi dilakukan pada setiap model (LeNet-5 dan AlexNet) dengan mengukur metrik seperti akurasi, presisi, recall, F1-score, dan confusion matrix. Akurasi menunjukkan prediksi yang benar, presisi mengukur ketepatan klasifikasi, recall menunjukkan kemampuan menangkap sampel relevan, dan F1-score memberikan keseimbangan antara presisi dan recall. Selain itu dilakukan juga analisis mencakup Loss Function untuk mengukur kesalahan model dan efisiensi komputasi, seperti waktu pelatihan dan inferensi.

Perbandingan Tiap Arsitektur


Setelah evaluasi, perbandingan antara LeNet-5 dan AlexNet dilakukan untuk menentukan model terbaik dalam klasifikasi daun teh, dengan fokus pada akurasi tinggi dan loss yang rendah. Model yang dipilih harus memiliki kinerja paling konsisten dan optimal pada data uji, serta mampu melakukan generalisasi dengan baik terhadap data baru. Jika hasil evaluasi belum optimal, penyesuaian dan optimasi hyperparameter seperti epoch, learning rate, dan batch size akan dilakukan untuk mencapai performa terbaik. Hasil evaluasi dan perbandingan antara LeNet-5 dan AlexNet dibahas berdasarkan metrik kinerja seperti akurasi, presisi, recall, F1-score, dan confusion matrix untuk menganalisis kesalahan klasifikasi. Analisis juga mencakup Loss Function, yang mengukur kemampuan model dalam mempelajari pola data. Kesimpulan akan menilai arsitektur mana yang paling optimal untuk klasifikasi daun teh, mempertimbangkan akurasi dan efisiensi komputasi.

3. Hasil Dan Pembahasan

Hasil

Proses awal sistem menunjukkan bahwa dataset daun teh versi 2 yang telah dilabeli melalui Roboflow berhasil diunduh dan diolah dengan baik. Dataset ini awalnya memiliki empat label kelas, yaitu 0, 1, 2, dan 3, namun label 0 dihapus karena tidak relevan. Label 1 (T2) dipetakan sebagai kategori Siap Panen, sedangkan label 2 (T3) dan label 3 (T4) digabung menjadi Belum Siap Panen. Proses ini disebut relabelling, yaitu penyederhanaan label untuk mengubah klasifikasi menjadi biner agar lebih fokus dan efisien. Dari seluruh data, sebanyak 4.198 gambar dinyatakan valid, sementara 1.542 file label dilewati karena tidak memiliki gambar yang sesuai. Gambar tersebut menunjukkan distribusi jumlah gambar sebelum dan sesudah pemetaan kelas. Sebelum pemetaan, data terdiri dari tiga kelas yaitu Kelas 1 sebanyak

1726 gambar, Kelas 2 sebanyak 1220 gambar, dan Kelas 3 sebanyak 1252 gambar. Setelah dilakukan pemetaan, kelas-kelas tersebut digabung menjadi dua kategori baru yaitu Belum Siap Panen sebanyak 2472 gambar dan Siap Panen sebanyak 1726 gambar. Distribusi ini ditampilkan pada Gambar 8.




Gambar 8. Distribusi kelas sebelum relabeling dan setelah relabeling

Setelah data terkumpul, sistem membaginya ke dalam dua kelompok utama yaitu data latih (training pool) dan data uji awal (initial test pool). Data latih berjumlah sekitar 3.831 gambar, sedangkan data uji awal berasal dari gabungan folder valid dan test, berjumlah 367 gambar. Karena target pengujian adalah 20% dari total data, sistem menyesuaikan jumlah dengan mengambil sebagian dari data latih jika data uji awal tidak mencukupi. Proses ini penting untuk menjaga keseimbangan dan memastikan bahwa evaluasi model dilakukan pada data yang representatif namun belum pernah dilatih sebelumnya.

Dalam penelitian ini, dua model Convolutional Neural Network (CNN) digunakan yaitu LeNet-5 dan AlexNet. Kedua model tersebut dilatih menggunakan data hasil pembagian akhir, dengan data uji digunakan sebagai validation data selama proses pelatihan. Dalam implementasinya digunakan metode EarlyStopping dan ModelCheckpoint untuk menghindari overfitting dan menyimpan model terbaik secara otomatis. Penggunaan dua arsitektur yang berbeda ini bertujuan untuk mengetahui mana yang lebih optimal dalam mengenali tingkat kematangan daun teh berdasarkan gambar, dengan mempertimbangkan kompleksitas model dan kemampuan generalisasi terhadap data baru.


1) Hasil LeNet-5

Berdasarkan grafik akurasi dan loss pada Gambar 9, pelatihan model LeNet-5 menunjukkan perkembangan yang cukup signifikan dalam hal peningkatan akurasi dan penurunan loss pada data pelatihan. Pada awal training, akurasi pelatihan meningkat tajam, di mana pada epoch pertama akurasi pelatihan mencapai 59,81% dan akurasi validasi langsung naik ke 68,21%. Ini menunjukkan bahwa model mulai mampu mengenali pola dasar pada data, walaupun akurasi validasi belum menunjukkan kestabilan pada epoch-epoch awal.



Gambar 9 Grafik Model LeNet-5

Pada epoch ke-6, akurasi validasi mencapai 71,67% dan akurasi pelatihan 93,72%, menjadi akurasi validasi terbaik selama pelatihan. Setelahnya, akurasi validasi stagnan. Loss pelatihan terus menurun stabil setelah lonjakan pada epoch 2–4, sedangkan loss validasi stagnan di sekitar 1,00. Pada epoch ke-22, pelatihan dihentikan oleh early stopping dengan akurasi pelatihan 99,98% dan loss 0,0199, sementara akurasi validasi turun ke 69,76% dengan loss 1,0028. Evaluasi dengan model terbaik menunjukkan akurasi validasi tetap di angka 71,67%, menandakan overfitting.



Gambar 10. Hasil Evaluasi LeNet-5; b. Hasil Confusion Matriks

Melihat dari confusion matrix pada Gambar 14, model LeNet-5 menunjukkan akurasi total sebesar 71,67%, namun performanya lebih unggul dalam mengklasifikasikan kelas "Belum Siap Panen" dibandingkan "Siap Panen". Model berhasil mengenali 505 data "Belum Siap Panen" dengan benar (True Negative) dan salah mengklasifikasikan 68 data sebagai "Siap Panen" (False Positive). Sebaliknya, hanya 97 data "Siap Panen" yang berhasil dikenali dengan benar (True Positive), sedangkan 170 lainnya salah diklasifikasikan sebagai "Belum Siap Panen" (False Negative). Ketimpangan ini kemungkinan dipengaruhi oleh distribusi data yang tidak seimbang, yaitu 573 data "Belum Siap Panen" dan 267 data "Siap Panen". Dari segi metrik evaluasi, kelas "Belum Siap Panen" memiliki precision sebesar 0,75, recall 0,88, dan f1-score 0,81, yang menunjukkan model cukup akurat dan sensitif terhadap kelas ini. Sebaliknya, kinerja pada kelas "Siap Panen" lebih rendah dengan precision 0,59, recall 0,36, dan f1-score 0,45, menunjukkan banyak prediksi salah dan model gagal

mengenali sebagian besar data pada kelas tersebut. Nilai macro average sebesar 0,63 dan weighted average 0,69 yang lebih rendah dari akurasi keseluruhan juga memperkuat indikasi ketidakseimbangan performa antar kelas. Dengan demikian, dapat disimpulkan bahwa model LeNet-5 lebih optimal dalam mengenali "Belum Siap Panen", namun masih lemah dalam mendeteksi "Siap Panen".

2) Hasil AlexNet

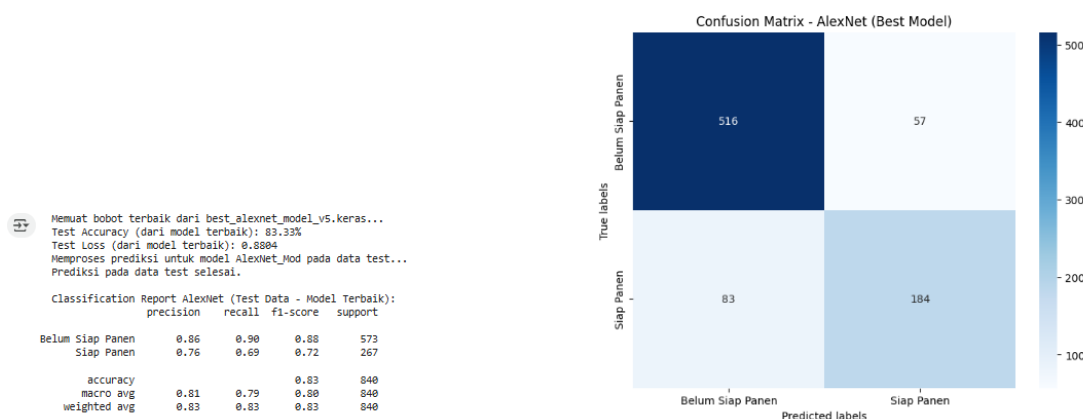
Sedangkan untuk hasil AlexNet yang ditunjukkan pada Gambar 9, juga menunjukkan perkembangan yang kurang stabil dalam hal akurasi dan loss selama proses training. Pada awalnya, akurasi pelatihan meningkat cukup tinggi, namun akurasi validasi masih cukup rendah. Pada epoch pertama, akurasi pelatihan tercatat sebesar 67,96%, sedangkan akurasi validasi hanya sebesar 65,95%. Hal ini menunjukkan bahwa meskipun model mulai belajar dari data pelatihan, kemampuan generalisasi terhadap data validasi masih terbatas.

Hasil Training AlexNet



Gambar 11 Grafik Model Alexnet

Proses pelatihan menunjukkan bahwa akurasi validasi meningkat pada epoch ke-2 (72,86%), ke-8 (78,45%), dan mencapai puncaknya di epoch ke-22 (83,33%) dengan akurasi pelatihan 95,84%. Setelah itu, akurasi validasi stagnan meski akurasi pelatihan terus meningkat hingga 97,03% di epoch ke-32. Grafik loss memperlihatkan penurunan stabil pada loss pelatihan (terakhir 0,0795), namun loss validasi fluktuatif di rentang 0,77–1,26, dan berakhir di angka 0,9178. Hal ini menunjukkan risiko overfitting, sehingga pelatihan dihentikan oleh early stopping.




Gambar 12. Hasil Evaluasi Alexnet; b. Hasil confusion matriks

Melihat dari confusion matrix pada Gambar 12, model AlexNet menunjukkan performa yang lebih baik untuk kelas "Belum Siap Panen" dibandingkan dengan kelas

"Siap Panen." Untuk kelas "Belum Siap Panen," model memprediksi dengan benar sebanyak 516 sampel dan salah 57 sampel. Sebaliknya, untuk kelas "Siap Panen," model memprediksi dengan benar sebanyak 184 sampel dan salah 83 sampel. Jumlah sampel "Belum Siap Panen" (573 data) lebih banyak dibandingkan dengan "Siap Panen" (267 data), yang menyebabkan ketidakseimbangan sensitivitas model. Berdasarkan classification report, untuk kelas "Belum Siap Panen," precision adalah 0,86, recall 0,90, dan f1-score 0,88. Untuk kelas "Siap Panen," precision 0,76, recall 0,69, dan f1-score 0,72. Akurasi model mencapai 83,33%, dengan macro average f1-score 0,80 dan weighted average 0,83. Secara keseluruhan, model lebih optimal dalam mengenali kategori "Belum Siap Panen," namun memiliki keterbatasan dalam mengidentifikasi kategori "Siap Panen."

3) Prediksi Citra Baru Menggunakan Model

Prediksi citra baru dilakukan dengan menguji gambar daun teh yang diunggah oleh pengguna dengan format jpg atau png, untuk menentukan apakah daun tersebut sudah siap panen atau belum. Proses dimulai dengan preprocessing citra, yang mencakup perubahan ukuran dan normalisasi agar sesuai dengan input yang dibutuhkan oleh model. Setelah itu, citra yang telah diproses tersebut dianalisis menggunakan dua model jaringan saraf konvolusional, yaitu AlexNet dan LeNet-5. Setiap model menghasilkan prediksi mengenai status kesiapan panen daun teh, yang disertai dengan nilai tingkat kepercayaan (*confidence*) yang menggambarkan keyakinan model terhadap prediksi yang diberikan.



Gambar 13. Hasil Prediksi Citra Baru Menggunakan Model

Pada hasil prediksi gambar daun teh yang diunggah, seperti yang ditampilkan pada Gambar 12, dua model yaitu AlexNet dan LeNet-5 memberikan hasil yang serupa namun dengan tingkat kepercayaan yang berbeda. Model AlexNet memprediksi bahwa daun teh tersebut adalah "Siap Panen" dengan tingkat kepercayaan sebesar 99,92%, menunjukkan tingkat keyakinan yang sangat tinggi terhadap prediksinya. Proses prediksi dengan AlexNet membutuhkan waktu sekitar 702 ms, yang mencerminkan efisiensi cukup cepat dalam pemrosesan gambar. Di sisi lain, model LeNet-5 juga memprediksi daun teh tersebut sebagai "Siap Panen", dengan tingkat

kepercayaan sebesar 97,84%. Meskipun sedikit lebih rendah dibandingkan AlexNet, tingkat kepercayaan ini tetap menunjukkan performa yang sangat baik. Proses inferensi menggunakan LeNet-5 bahkan lebih cepat, yakni hanya membutuhkan sekitar 277 ms. Hal ini mengindikasikan bahwa kedua model konsisten dalam pengambilan keputusan, dengan AlexNet memberikan keyakinan prediksi yang sedikit lebih tinggi, sementara LeNet-5 menawarkan kecepatan pemrosesan yang lebih baik.

Pembahasan

Berdasarkan hasil pelatihan model LeNet-5 dan AlexNet, kedua model menunjukkan gejala overfitting. Pada LeNet-5, akurasi pelatihan mencapai 99,98% pada epoch ke-22, namun akurasi validasi hanya 69,76%, dengan puncaknya 71,67% pada epoch ke-6. Hal serupa terjadi pada AlexNet, yang mencapai akurasi pelatihan 97,03% pada epoch ke-32, sementara akurasi validasi terbaik hanya 83,33% pada epoch ke-22. Kedua model ini terlalu menyesuaikan diri dengan data pelatihan, sehingga kesulitan dalam menggeneralisasi data baru. Fenomena overfitting ini dapat dijelaskan melalui konsep bias-variance tradeoff, di mana model dengan kapasitas besar cenderung memiliki variance tinggi dan kurang mampu menggeneralisasi data baru. Baik LeNet-5 maupun AlexNet menunjukkan kemampuan mempelajari fitur kompleks data pelatihan, namun tidak cukup robust untuk menggeneralisasi data validasi, terbukti dari stagnasi akurasi validasi setelah beberapa epoch. Meskipun keduanya mengalami overfitting, AlexNet menunjukkan akurasi pengujian yang lebih baik dibandingkan LeNet-5.

Akurasi pengujian AlexNet mencapai 83,33%, lebih tinggi dibandingkan LeNet-5 yang hanya 71,67%, menunjukkan bahwa AlexNet lebih efektif dalam mengenali pola pada data uji. Berdasarkan confusion matrix dan classification report, kedua model lebih optimal dalam mengidentifikasi kelas "Belum Siap Panen" daripada "Siap Panen". LeNet-5 memiliki precision 0,75, recall 0,88, dan f1-score 0,81 untuk "Belum Siap Panen", sementara AlexNet mencatatkan precision 0,86, recall 0,90, dan f1-score 0,88. AlexNet juga lebih seimbang dengan f1-score macro average 0,80, lebih tinggi dari LeNet-5 yang hanya 0,63. Secara keseluruhan, AlexNet lebih unggul dalam akurasi dan keseimbangan performa antar kelas, meskipun LeNet-5 lebih efisien dalam kecepatan inferensi.

4. Simpulan

Sehingga berdasarkan hasil tersebut, dapat disimpulkan bahwa model LeNet-5 menunjukkan akurasi pelatihan yang sangat tinggi (99,98%), namun akurasi validasi stagnan di sekitar 69,76%, yang mengindikasikan adanya overfitting. Model ini berhasil mengklasifikasikan kelas "Belum Siap Panen" dengan baik, namun kesulitan dalam mengklasifikasikan kelas "Siap Panen". Akurasi pengujian mencapai 71,67% dengan loss 1,0028. Meskipun memiliki kecepatan pemrosesan yang lebih baik, kemampuan generalisasi terhadap data baru, terutama kelas "Siap Panen", masih kurang optimal. Sedangkan AlexNet menunjukkan hasil yang lebih baik dibandingkan LeNet-5 dalam hal akurasi dan kemampuan generalisasi. Model ini mencapai akurasi pengujian 83,33% dengan loss 0,9178. Precision dan recall pada kategori "Siap Panen" cukup baik dengan f1-score 0,72. Meskipun mengalami overfitting, AlexNet lebih

unggul dalam menangani data kompleks dan menghasilkan prediksi yang lebih akurat, serta lebih efektif dalam mengklasifikasikan kedua kategori dibandingkan LeNet-5.

Perbandingan antara kedua arsitektur menunjukkan bahwa meskipun LeNet-5 lebih efisien dalam hal waktu pemrosesan, AlexNet jauh lebih unggul dalam hal akurasi klasifikasi daun teh siap panen. AlexNet memiliki keunggulan dalam menangani data yang lebih kompleks, meskipun kedua model sama-sama mengalami overfitting. LeNet-5 lebih cepat, namun kesulitan dalam generalisasi, terutama pada kelas "Siap Panen", sementara AlexNet lebih mampu menangani perbedaan antar kelas dengan lebih baik, meskipun memerlukan waktu pemrosesan yang sedikit lebih lama.

Untuk penelitian selanjutnya, disarankan untuk memperluas variasi dataset dengan menambahkan lebih banyak gambar daun teh dalam kondisi yang lebih beragam, termasuk faktor lingkungan yang berbeda. Selain itu, penggunaan arsitektur model yang lebih canggih, seperti ResNet atau VGG, serta penerapan teknik regularisasi seperti dropout dan L2 regularization, dapat membantu mengurangi overfitting dan meningkatkan kemampuan generalisasi model. Penelitian lanjutan juga dapat mengeksplorasi penggunaan transfer learning dengan memanfaatkan model pre-trained untuk meningkatkan akurasi, serta mengintegrasikan model ke dalam aplikasi nyata untuk membantu petani teh dalam menentukan waktu panen yang optimal.

5. Daftar Pustaka

- Al Rivan, M. E., & Riyadi, A. G. (2021). Perbandingan arsitektur lenet dan alexnet pada metode convolutional neural network untuk pengenalan american sign language. *Jurnal Komputer Terapan*, 7(1), 53–61.
- Arrofiqoh, E. N., & Harintaka, H. (2018). Implementasi metode convolutional neural network untuk klasifikasi tanaman pada citra resolusi tinggi. *Geomatika*, 24(2), 61.
- Bismi, W., & Harafani, H. (2022). Perbandingan Metode Deep Learning dalam Mengklasifikasi Citra Scan MRI Penyakit Otak Parkinson. *InComTech J. Telekomun. Dan Komput*, 12(3), 177–185.
- Ernawati, T. (2024). METODE KLASIFIKASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) PADA PENYAKIT DAUN TEH. *Jurnal Informasi Dan Komputer*, 12(02), 97–102.
- Ferdiansyah, M. R., & Zamzami, A. (2022). Evaluasi Metode Pemetikan Teh (*Camellia sinensis* (L.) O. Kuntze) untuk Memproduksi Teh Hijau di Perkebunan Teh Negara Kanaan, Bandung. *Buletin Agrohorti*, 10(3), 440–449.
- Indonesia-Investment. (2024). *Laporan Teh di Indonesia - Analisis Perkebunan, Produksi, Konsumsi & Ekspor / Indonesia Investments*. <https://www.indonesia-investments.com/id/bisnis/komoditas/teh/item240>
- Isnur. Putri. (2024). *Seberapa Besar Produksi Teh di Indonesia?* <https://indonesiabaik.id/infografis/seberapa-besar-produksi-teh-di-indonesia>
- Maska, D. W. A. (2022). Penanganan Panen dan Pascapanen Teh Hitam CTC (*Camellia sinensis* (L.) O. Kuntze) di Kebun Rancabali, Bandung, Jawa Barat. *Buletin Agrohorti*, 10(3), 397–407.
- Prastiwi, A. E., & Lontoh, A. P. (2019). Manajemen Pemetikan Tanaman Teh (*Camelia Sinensis* (L.) O. Kuntze) di Unit Perkebunan Tambi, Wonosobo, Jawa Tengah. *Buletin Agrohorti*, 7(1), 115–122.
- Roboflow. (2023). *Tea Leaves Dataset Model > Overview*. <https://universe.roboflow.com/tea-dataset-w9n3c/tea-leaves-dataset>

Tarisa, E., & Ariany, F. (2024). PERBANDINGAN KINERJA DEEP LEARNING LENET DAN ALEXNET DENGAN AUGMENTASI DATA PADA IDENTIFIKASI ANGGREK. *JIKA (JURNAL INFORMATIKA)* Учредители: Universitas Muhammadiyah Tangerang, 8(1), 51.