
Klasifikasi Cuaca Berbasis Citra dengan Model CNN LeNet-5 yang Dimodifikasi

Miranda Sahfira Tuna^{1*}, Aries Kristianto²

^{1,2} Meteorologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Jl. Meteorologi No.5, Tanah Tinggi, Kec. Tangerang, Kota Tangerang, Banten, 15221, Indonesia

***Email Korespondensi:**

miranda.tuna@bmet.go.id

Abstrak

Perkembangan teknologi di bidang informasi cuaca sangatlah dibutuhkan khususnya bagi seluruh aspek kehidupan. Untuk mengenali, mempelajari, hingga mendeteksi kondisi cuaca yang terjadi, perlu adanya teknik klasifikasi dengan bantuan artificial intelligence. Model klasifikasi yang digunakan adalah convolutional neural network (CNN) dengan arsitektur LeNet-5 yang dimodifikasi. Tujuan dari penelitian ini untuk menguji kinerja model terhadap klasifikasi kondisi cuaca cerah, cerah berawan, berawan dan hujan, serta mengetahui akurasi yang dihasilkan dan pengaplikasiannya. Dengan model tersebut. Ukuran citra yang digunakan adalah 224x224, ukuran batch 32, learning rate 0,0001 dan dilatih dengan 50 epoch. Pada proses pelatihan model, dibuat 8 skenario berbeda yang melibatkan teknik augmentasi dan tanpa augmentasi, serta penggunaan salah satu fungsi callbacks berupa earllystopping. Model CNN yang menggunakan augmentasi dan earllystopping dengan nilai patience 5 menghasilkan perform yang paling baik karena mencapai akurasi hingga 94%. Model tersebut diimplementasikan pada situs web yang di-host secara lokal dan menghasilkan prediksi yang sesuai dengan kondisi cuaca yang terjadi.

Kata Kunci : CNN; Cuaca; Deep Learning; Klasifikasi; Prediksi

Abstract

The development of technology in the field of weather information is needed especially for all aspects of life. To recognize, study, and detect weather conditions that occur, classification techniques with the help of artificial intelligence are needed. The classification model used is a convolutional neural network (CNN) with a modified LeNet-5 architecture. The purpose of this study is to test the performance of the model for the classification of sunny, cloudy, cloudy and rainy weather conditions, as well as to determine the resulting accuracy and its application. With this model. The image size used is 224x224, batch size 32, learning rate 0.0001 and trained with 50 epochs. In the model training process, 8 different scenarios were created involving augmentation and no augmentation techniques, as well as the use of one of the callbacks functions in the form of earllystopping. The CNN model that uses augmentation and earllystopping with a patience value of 5 produces the best performance because it achieves an accuracy of up to 94%. The model is implemented on a locally hosted website and produces predictions that match the weather conditions that occur.

Keywords: Classification; CNN; Deep Learning; Prediction ; Weather

1. Pendahuluan

Perkembangan teknologi di bidang informasi cuaca sangatlah dibutuhkan khususnya bagi seluruh aspek kehidupan. Cuaca dapat berubah dari cerah menjadi berawan, berawan menjadi hujan, hujan menjadi hujan petir ataupun sebaliknya. Perubahan cuaca secara signifikan dapat mempengaruhi aktivitas manusia seperti perkebunan, pertanian, penerbangan dan kelautan. BMKG dalam hal ini menjalankan tupoksinya dengan mengeluarkan prakiraan cuaca baik harian maupun beberapa hari kedepan. Namun prediksi tidak selamanya akan terjadi atau seratus persen akurat, tetapi bisa ditingkatkan dengan berbagai teknik yang ada (Dama et al.,

2021). Untuk mengenali dan mempelajari kondisi cuaca yang terjadi, perlu adanya teknik klasifikasi yang baik agar kemungkinan perubahan yang terjadi dapat dideteksi dengan akurat. Teknik klasifikasi yang dapat menentukan suatu objek salah satunya yaitu dengan bantuan artificial intelligence (Suryanto, 2014).

Artificial intelligence (AI) merupakan kecerdasan buatan yang kerap dilihat sebagai teknologi masa depan untuk membantu manusia memahami sejarah dengan lebih mendalam (Wibawa et al., 2024).ja Dalam penggunaannya, AI dapat diaplikasikan untuk berbagai bidang seperti pengontrol, peramalan, perencanaan dan image processing (Jaya et al., 2018). AI terbagi menjadi beberapa cabang salah satunya yaitu machine learning (ML), yang mampu mempelajari suatu informasi secara mandiri berdasarkan algoritma dan data historisnya. Seiring berkembangnya zaman, ML mengalami kemajuan hingga membentuk turunan baru bernama Deep Learning (DL). Turunan ML ini menjadi semakin hebat dalam menangani dataset berskala besar melampaui kemampuan manusia (Suyanto, 2021). Pemanfaatan salah satu jenis DL menunjukkan bahwa model Convolutional Neural Network (CNN) memiliki performa yang sangat baik dalam mengklasifikasikan atau mendeteksi suatu objek berbasis pemrosesan citra (Heryadi & Irwansyah, 2020).

CNN adalah jenis jaringan multi-layer sangat khusus yang terdiri dari banyak neuron buatan dan dirancang untuk mengenali pola visual langsung dari gambar dengan pemrosesan minimal (Sewak et al., 2018). CNN termasuk ke dalam kelas deep feed-forward artificial neural networks yang memiliki arsitektur sangat sederhana berupa satu lapis masukan (input layer), satu lapis keluaran (output layer) dan sejumlah lapis tersembunyi (hidden layers). Para ahli merancang berbagai model dengan lebih banyak lapisan seperti GoogleNet, VGGNet dan ResNet. Namun tiga arsitektur model yang cukup populer pada awal kemunculan CNN yaitu AlexNet, ZFNet dan LeNet-5 (Suyanto et al., 2019).

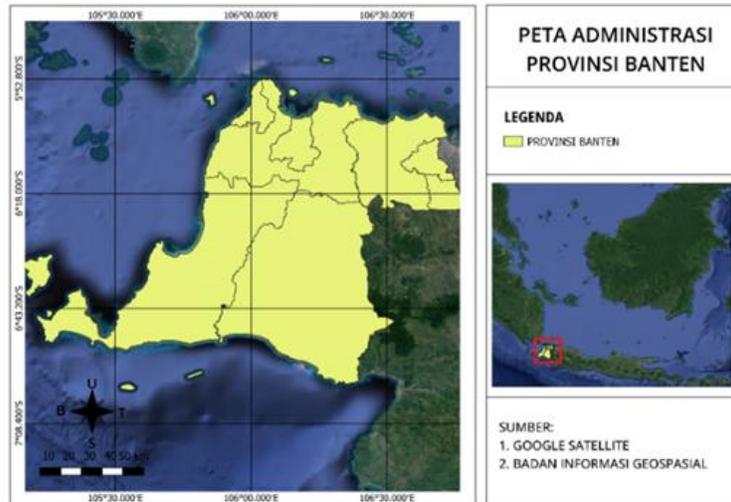
LeNet-5 adalah salah satu arsitektur CNN klasik pertama yang menunjukkan hasil mengagumkan dalam mengatasi masalah pengenalan tulisan tangan (Lecun et al., 1998). Dalam demonstrasi konsep arsitekturnya, LeCun mengurangi tinggi dan lebar melalui konvolusi, meningkatkan ukuran filter/channel, dan memiliki fully connected layer, yang sekarang menjadi kekuatan semua kerangka kerja CNN (Kamath et al., 2019). Motif utama di balik ketenaran model ini adalah arsitekturnya yang sederhana dan lugas sebagai jaringan saraf konvolusi multi-layer untuk klasifikasi gambar.

Penelitian yang berkaitan dengan klasifikasi kondisi cuaca telah banyak dilakukan menggunakan berbagai metode. Misalnya, Budi dkk. (2021)(Budi et al., 2021), menggunakan algoritma CNN dengan arsitektur VGG16net, sementara Naufal (2021) membandingkan algoritma Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan CNN dengan arsitektur LeNet. Sharma dan Ismail (2022) menggunakan algoritma CNN dengan framework Keras dan library TensorFlow(Sharma & Ismail, 2022), sedangkan An dkk. (2018) mengkombinasikan AlexNet dan ResNet CNN dengan SVM multi-kelas(An et al., 2018). Selain itu, Naufal dan Kusuma (2021) memanfaatkan metode transfer learning pada CNN untuk meningkatkan performa model. Penelitian-penelitian tersebut menunjukkan bahwa model berbasis CNN sangat efektif dalam mengklasifikasikan kondisi cuaca(Naufal & Kusuma, 2022).

Namun, sebagian besar penelitian tersebut hanya berfokus pada penggunaan arsitektur CNN modern atau transfer learning tanpa memanfaatkan arsitektur LeNet-5, terutama untuk data cuaca lokal. Penelitian sebelumnya yang menggunakan arsitektur LeNet-5, seperti yang dilakukan oleh (Alwanda et al., 2020) untuk pengenalan doodle dan (IBRAHIM et al., 2022) untuk klasifikasi grade telur ayam negeri secara non-invasive, menunjukkan performa yang sangat baik dengan akurasi di atas 85%. Akan tetapi, studi terkait pemanfaatan LeNet-5 untuk klasifikasi kondisi cuaca masih minim, terutama untuk mengatasi variasi pola cuaca yang kompleks. Oleh karena itu, penelitian ini bertujuan untuk mengetahui kemampuan/kinerja dan akurasi model yang dibangun dengan modifikasi arsitektur LeNet-5 dalam mengklasifikasikan kondisi cuaca beserta pengaplikasiannya.

2. Metode Penelitian

Penelitian dilakukan di wilayah Provinsi Banten yang disajikan pada Gambar 3.1 dengan letak astronomis pada 105°01'11" - 106°07'12" Bujur Timur dan 05°07'50" - 07°01'01" Lintang Selatan. Waktu penelitian ini yaitu pada bulan Mei 2022 – Mei 2023.



Gambar 1. Peta Lokasi Penelitian

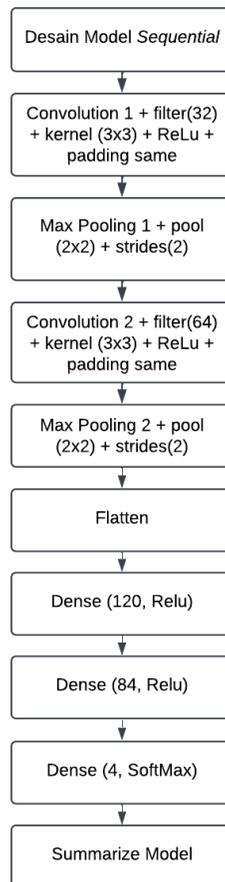
Proses pengumpulan data diperoleh dari hasil tangkapan kamera smartphone dan IP Camera Stasiun Meteorologi Cengkareng Soekarno Hatta yang meliputi 4 macam kondisi cuaca yaitu cerah, cerah berawan, berawan dan hujan dengan jangka waktu selama 1 tahun (Mei 2022 – Mei 2023). Total data yang digunakan berjumlah sebanyak 5.323 citra dan dibagi ke dalam 3 jenis directory yaitu train, validation, dan testing.

Tabel 1. Perbandingan jumlah dan sebaran data

Kondisi cuaca	Sampel Citra	Jumlah	Data <i>train</i> (70%)	Data <i>validation</i> dan <i>testing</i> (30%)
Cerah		1.593	1.115	478
Cerah berawan		1.049	734	315
Berawan		1.536	1.074	462
Hujan		1.145	801	344

Preprocessing dilakukan dengan mengubah ukuran citra dan augmentasi data. Dimensi citra di-resize menjadi 224x224 piksel untuk menyeragamkan dan mempercepat proses pengenalan citra (Marcella et al., 2022). Pada tahap ini juga dibuat beberapa skenario dengan melakukan augmentasi data dan tanpa augmentasi. Augmentasi data menggunakan ImageDataGenerator dengan melakukan rotation range, zoom range, dan horizontal flip, sebagaimana yang diusulkan oleh Naufal et al. (2022)(Naufal & Kusuma, 2022). Teknik ini

dipilih karena terbukti dapat meningkatkan keberagaman data dan mengurangi risiko overfitting pada model yang dibangun.



Gambar 2. Proses rancangan model CNN

Penelitian ini menggunakan rancangan model arsitektur LeNet-5 sebagai dasar model CNN karena desainnya yang sederhana dan telah terbukti efektif dalam pengenalan pola. Namun dilakukan beberapa perubahan pada struktur atau komponen arsitektur untuk meningkatkan performa model dan menyesuaikan dengan dataset yang digunakan. Modifikasi yang dilakukan yaitu menambahkan jumlah filter pada lapisan konvolusi pertama dan kedua, mengubah fungsi aktivasi menjadi ReLU, mengganti average pooling dengan max pooling, serta menambahkan dua lapisan dense sebelum lapisan output akhir yang menggunakan fungsi softmax untuk klasifikasi banyak kelas (Rizal et al., 2022).

Dalam proses pelatihan model, optimizer yang digunakan adalah adam dengan learning rate 10^{-4} dan loss categorical crossentropy. Selanjutnya model dilatih dengan jumlah epoch sebanyak 50 epoch (Naufal & Kusuma, 2022). Pada proses pelatihan model, dibuat beberapa skenario dengan melibatkan penggunaan salah satu fungsi callbacks yaitu earlystopping yang berguna untuk menghentikan pelatihan model lebih awal jika akurasi atau loss tidak stabil (Kirana, 2022).

Model diuji menggunakan data testing. Pengujian model memberikan output berupa klasifikasi yang telah dilatih pada proses sebelumnya. Performa model kemudian dianalisis menggunakan confusion matrix dan metric yang menghasilkan nilai accuracy, precision, recall dan f1-score (Indriani.S et al., 2024).

Tabel 2. Confusion Matriks

Confusion Matrix		Nilai Prediksi	
		Positif	Negatif
Nilai Sebenarnya	Positif	TP	FP
	Negatif	FN	TN

Keterangan :

- TP (*True Positive*) adalah prediksi benarnya data positif
- TN (*True Negative*) adalah prediksi benarnya data negatif
- FP (*False Positive*) adalah data negatif yang diprediksi sebagai data positif
- FN (*False Negative*) adalah data positif yang diprediksi sebagai data negatif

Akurasi merepresentasikan perbandingan antara kejadian (positif dan negatif) yang benar diprediksi dengan total data yang ada. Nilai akurasi berada pada rentang antara 0 hingga 1 yang selanjutnya dapat dikonversi dalam bentuk persentase.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (1)$$

Presisi adalah tingkat kemampuan model dalam memprediksi kejadian positif dari keseluruhan prediksi positif (benar dan salah). Persamaannya dapat ditulis sebagai berikut.

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

Recall artinya perbandingan antara kejadian positif yang diprediksi benar dengan keseluruhan kejadian benar positif. Recall menandakan model berhasil menemukan kembali suatu informasi.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

F1-Score merupakan rasio rata-rata precision dan recall yang dijumlahkan. Jika jumlah prediksi kejadian negatif mendekati jumlah prediksi kejadian positif, maka F1-Score dapat digunakan sebagai acuan performansi algoritma.

$$\text{F1 - score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Setelah melewati proses pelatihan model, model yang memiliki performa paling baik di-save dalam format file .h5. Model diimplementasikan secara internal pada sebuah website dan tidak dipublikasikan ke internet secara terbuka atau hanya dapat diakses oleh perangkat yang terhubung dengan jaringan lokal yang sama (localhost).

3. Hasil

Pada penelitian ini, terdapat 8 skenario berbeda yang memvariasikan penggunaan teknik augmentasi dan pengaturan earlystopping pada nilai parameter patience. Skenario 1-4 melibatkan teknik augmentasi, sedangkan skenario 5-8 tidak menggunakan teknik augmentasi. Skenario percobaan dibuat untuk mengevaluasi dan menentukan model yang memiliki variasi dan kualitas data pelatihan terbaik.

Tabel 3. Skenario Percobaan Model CNN

Skenario	Deskripsi skenario	Accuracy		Loss		Waktu
		Train	Valid	Train	Valid	
1	Augmentasi + A1	96.35%	92.68%	0.10	0.22	1:05:21
2	Augmentasi + A2	96.73%	93.62%	0.09	0.17	1:25:30
3	Augmentasi + A3	98.58%	93.18%	0.04	0.27	4:05:45

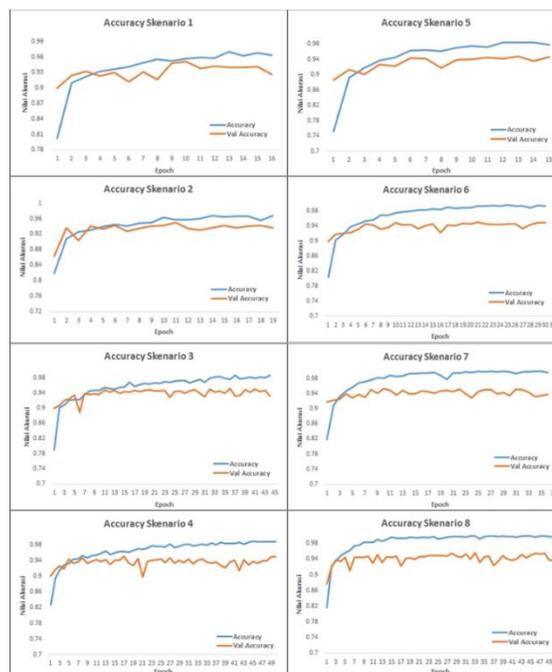
Skenario	Deskripsi skenario	Accuracy Train	Loss Valid	Waktu Train	Skenario	Deskripsi skenario
4	Augmentasi + A4	98.79%	94.93%	0.03	0.21	3:28:01
5	A1 + Tanpa Augmentasi	97.74%	94.62%	0.06	0.16	1:56:11
6	A2 + Tanpa Augmentasi	99.33%	94.81%	0.01	0.19	1:38:25
7	A3 + Tanpa Augmentasi	99.49%	93.75%	0.01	0.28	1:32:38
8	A4 + Tanpa Augmentasi	99.60%	93.68%	0.01	0.30	2:40:27

Keterangan:

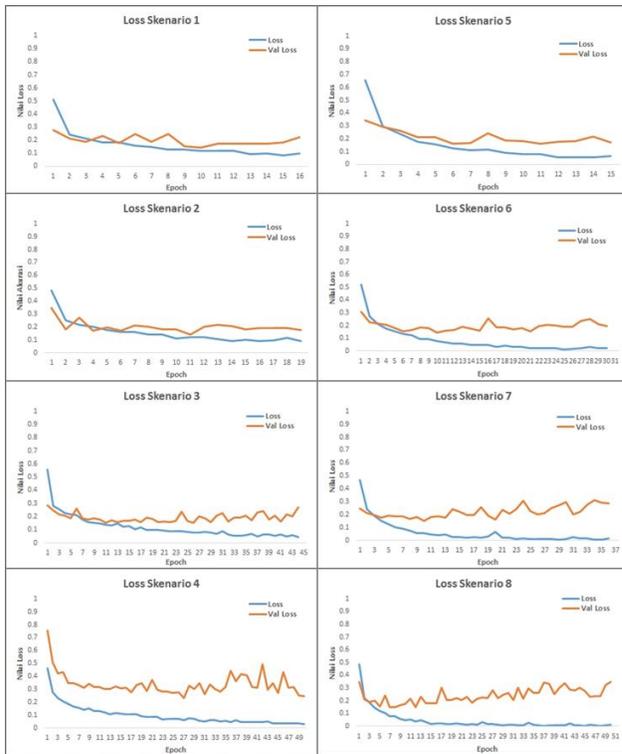
- A1 = Earlystopping dengan patience 3
- A2 = Earlystopping dengan patience 5
- A3 = Earlystopping dengan patience 7
- A4 = Tanpa earlystopping

Tabel 3 menunjukkan bahwa skenario model tanpa augmentasi cenderung memiliki akurasi yang lebih tinggi dengan loss yang lebih rendah dibandingkan dengan skenario 1 hingga 4 (dengan augmentasi). Meskipun akurasinya tinggi, namun nilai antara train dan validasinya menunjukkan kesenjangan yang lebih besar. Perbedaan nilai tersebut mengindikasikan bahwa model tanpa augmentasi cenderung overfitting. Dari segi waktu pelatihan, skenario 3 dan 4 membutuhkan waktu pelatihan yang lebih lama dibandingkan dengan skenario lainnya.

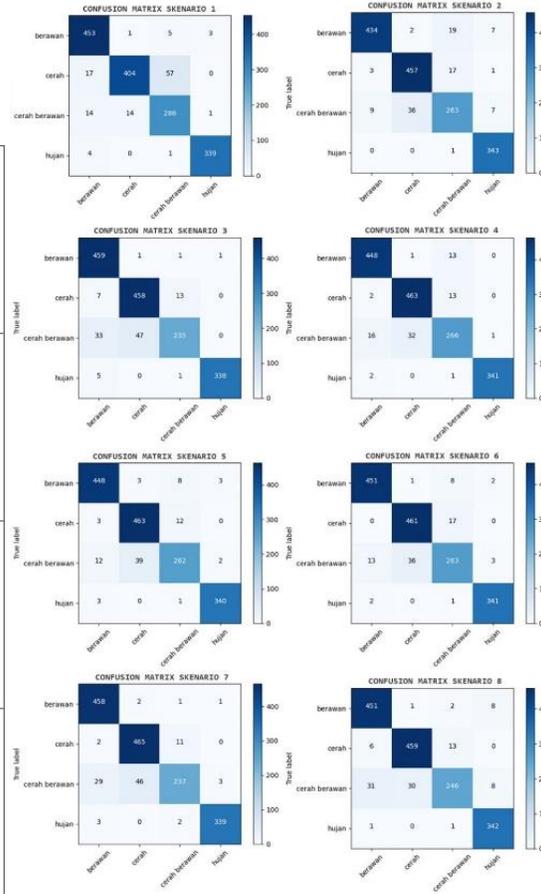
Untuk memantau kinerja model selama proses pelatihan, mengevaluasi performa pada data pelatihan dan pengujian, serta memilih model terbaik dari beberapa model yang dibandingkan, dapat dilakukan dengan memonitor grafik perbandingan akurasi dan loss model. Perbandingan grafik akurasi dan loss seperti yang ditampilkan pada gambar 3 dan 4 di bawah ini menggambarkan informasi tentang peningkatan atau penurunan performa model seiring dengan berjalannya epoch.



Gambar 3. Perbandingan Grafik Akurasi



Gambar 4. Perbandingan Grafik Loss



Gambar 5. Hasil Confusion Matriks

Dapat dilihat bahwa penggunaan earlystopping pada ke-6 skenario mempengaruhi titik penghentian pelatihan model. Pada skenario 1, pelatihan model berhenti di epoch ke-16; Skenario 2 pada epoch ke-19; Skenario 3 pada epoch ke-45; Skenario 5 pada epoch ke-15; skenario 6 pada epoch ke-31; skenario 7 pada epoch ke-37. Secara keseluruhan, akurasi pelatihan pada ke-8 skenario mengalami peningkatan dan loss yang menurun seiring berjalannya pelatihan model. Sedangkan masing-masing nilai validasinya bervariasi antara loss dan akurasi. Berdasarkan grafik tersebut, model yang memiliki performa paling baik adalah skenario 2 yang menggunakan teknik augmentasi dan earlystopping dengan nilai patience 5, karena menghasilkan perbedaan nilai yang lebih kecil dibandingkan dengan skenario lainnya.

Model CNN yang telah dilatih dengan 8 skenario selanjutnya diuji menggunakan data testing yang berjumlah sebanyak 1599 citra. Data cerah sebanyak 478 citra, data cerah berawan sebanyak 315 citra, data berawan sebanyak 462 citra dan data hujan sebanyak 344 citra. Dalam pengujian ini, data testing digunakan untuk menguji kemampuan model dalam mengklasifikasikan data baru yang tidak pernah dilihat sebelumnya.

Hasil klasifikasi pada berbagai skenario seperti yang ditunjukkan pada gambar 5, menunjukkan variasi jumlah citra yang berhasil dikelompokkan dengan benar. Secara keseluruhan, model menunjukkan akurasi yang baik dengan jumlah citra yang benar antara 1482 hingga 1518 citra, tergantung pada masing-masing skenario. Pada skenario 1 hingga 8, masing-masing kategori citra (cerah, cerah berawan, berawan dan hujan) memiliki jumlah yang berhasil diprediksi dengan benar.

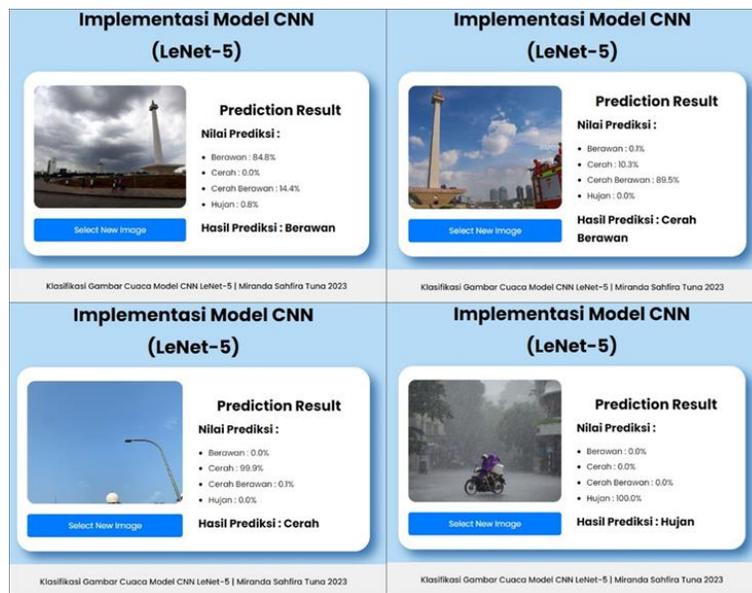
Tabel 4. Metrik Evaluasi Model CNN

Skenario	Precision				Recall				F1-score				Akurasi
	B	C	CB	H	B	C	CB	H	B	C	CB	H	
1	0.98	0.85	0.91	0.99	0.93	0.96	0.82	0.99	0.95	0.90	0.86	0.99	0.93
2	0.94	0.96	0.83	1.00	0.97	0.92	0.88	0.96	0.96	0.94	0.86	0.98	0.94
3	0.99	0.96	0.75	0.98	0.91	0.91	0.94	1.00	0.95	0.93	0.83	0.99	0.93
4	0.97	0.97	0.84	0.99	0.96	0.93	0.91	1.00	0.96	0.95	0.88	0.99	0.95
5	0.97	0.97	0.83	0.99	0.96	0.92	0.93	0.99	0.97	0.94	0.88	0.99	0.95
6	0.98	0.96	0.83	0.99	0.97	0.93	0.91	0.99	0.97	0.94	0.87	0.99	0.95
7	0.99	0.97	0.75	0.99	0.93	0.91	0.94	0.99	0.96	0.94	0.84	0.99	0.94
8	0.98	0.96	0.78	0.99	0.92	0.94	0.94	0.96	0.95	0.95	0.85	0.97	0.94

Keterangan:

- B = Berawan
- CB = Cerah Berawan
- C = Cerah
- H = Hujan

Dari gambar 6, dapat dilihat bahwa nilai akurasi testing tertinggi mencapai 95% dihasilkan oleh model dengan skenario 4, 5 dan 6. Kemudian, diikuti oleh skenario 2,7 dan 8 dengan akurasi mencapai 94%. Terakhir adalah skenario 1 dan 3 dengan akurasi sebesar 93%. Namun, untuk hasil metrik evaluasi lainnya, terlihat bahwa skenario 3, 7 dan 8 memiliki nilai precision yang lebih rendah untuk citra cerah berawan yakni $\leq 78\%$. Sehingga tahap pengaplikasian model dalam penelitian ini menggunakan model yang dibangun dengan skenario 2. Meskipun akurasi testing lebih rendah dari skenario 4, 5 dan 6 dengan selisih 1%, namun skenario ini menunjukkan tren yang lebih baik.



Gambar 6. Hasil Prediksi Model Berbasis Website

Gambar 6 menunjukkan bahwa inputan sampel citra yang mewakili masing-masing kondisi menghasilkan nilai probabilitas yang tinggi sehingga dapat diprediksi dengan tepat dan benar oleh model. Model memprediksi citra hujan dengan nilai probabilitas 100%. Citra berawan diprediksi dengan akurasi 84.8%, citra cerah berawan diprediksi dengan akurasi 89.5%, dan citra cerah diprediksi dengan akurasi 99.9%.

4. Pembahasan

Hasil penelitian menunjukkan bahwa model CNN berbasis arsitektur LeNet-5 yang dimodifikasi mampu mengklasifikasikan kondisi cuaca dengan baik. Berdasarkan hasil skenario pelatihan dan pengujian, penggunaan augmentasi data dan earlystopping dengan nilai patience 5 (skenario 2) menghasilkan model yang paling seimbang, dengan perbedaan kecil antara akurasi pelatihan dan validasi. Hal ini menunjukkan kemampuan generalisasi model yang lebih baik dibandingkan skenario lainnya, khususnya skenario tanpa augmentasi yang menunjukkan indikasi overfitting meskipun akurasi pelatihannya lebih tinggi.

Jika dibandingkan dengan penelitian sebelumnya, model dalam penelitian ini memberikan performa yang sebanding. Naufal (2021) membangun model CNN dengan akurasi sebesar 94% dengan hasil metrik evaluasi yang memadai (Naufal, 2021). Penelitian (An et al., 2018) juga menunjukkan akurasi model mencapai 97% hingga 100% untuk berbagai kondisi cuaca dan sejalan dengan penelitian yang dilakukan. Selain itu, penelitian Budi et al. (2021) menunjukkan bahwa model CNN mampu mengklasifikasikan kondisi cuaca dengan baik, dengan akurasi sekitar 87%, yang mencerminkan keberhasilan CNN dalam menangani data cuaca tanpa overfitting (Budi et al., 2021).

Penelitian ini juga menegaskan bahwa augmentasi data memainkan peran penting dalam meningkatkan kemampuan generalisasi model, sejalan dengan hasil Naufal dan Kusuma (2021) (Naufal, 2021), yang menunjukkan bahwa augmentasi dan transfer learning dapat meningkatkan performa model. Namun, waktu pelatihan yang lebih lama pada skenario augmentasi (misalnya, skenario 3 dan 4) menjadi salah satu pertimbangan untuk memilih skenario dengan hasil terbaik namun waktu pelatihan yang efisien.

Model yang diimplementasikan dalam website lokal memberikan hasil prediksi yang sesuai untuk semua kategori cuaca, mencerminkan keberhasilan pengujian pada data baru. Dengan demikian, model ini dapat diintegrasikan ke dalam sistem prakiraan cuaca untuk mendukung pengambilan keputusan. Dari segi penggunaan memori, struktur model yang dibangun relatif lebih ringan dibandingkan dengan model yang lebih kompleks, seperti ResNet atau VGG, yang memungkinkan model ini dapat diimplementasikan pada perangkat dengan kapasitas memori terbatas, yang seringkali menjadi tantangan dalam aplikasi real-time. Sedangkan dalam hal waktu inferensi, model menunjukkan kemampuan untuk menghasilkan prediksi dengan cepat, yang sangat penting dalam aplikasi real-time. Kecepatan inferensi ini memastikan bahwa model memberikan hasil yang akurat dalam waktu singkat, tanpa menyebabkan keterlambatan yang dapat mengganggu efektivitas aplikasi.

5. Kesimpulan

Model CNN memiliki performa yang baik dalam mengklasifikasikan kondisi cuaca dengan hasil akurasi pelatihan mencapai 96.73% dan loss sebesar 0.09. Total citra sebanyak 5.323 citra yang terbagi menjadi 4 kelas cuaca dengan rasio pembagian 70% sebagai data training dan 30% sisanya sebagai validation dan testing. Pada pengaplikasian model berbasis website, masing-masing citra yang mewakili kondisi cuaca tersebut dapat diprediksi dengan benar oleh model. Untuk pengembangan lebih lanjut, disarankan untuk melakukan uji coba model ini pada dataset yang lebih bervariasi, yang mencakup lebih banyak kondisi cuaca yang lebih kompleks seperti kabut, badai, atau fenomena cuaca ekstrem lainnya. Selain itu, dengan kemampuannya dalam memberikan hasil prediksi yang cepat, model ini dapat diintegrasikan ke dalam sistem prakiraan cuaca yang dapat memberikan informasi secara langsung kepada pengguna.

Referensi

- Alwanda, M. R., Ramadhan, R. P. K., & Alamsyah, D. (2020). Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle. *Jurnal Algoritme*, 1(1), 45–56. <https://doi.org/10.35957/algoritme.v1i1.434>
- An, J., Chen, Y., & Shin, H. (2018). Weather Classification using Convolutional Neural Networks. *2018 International SoC Design Conference (ISOC)*, 245–246. <https://doi.org/10.1109/ISOC.2018.8649921>
- Budi, R. S., Patmasari, R., & Saidah, S. (2021). Klasifikasi Cuaca Menggunakan Metode Convolutional Neural Network. *EProceedings of Engineering*.
- Dama, H. R. A., Supianto, A. A., & Setiawan, N. Y. (2021). Analisis Penggunaan Model Regresi untuk Prediksi Penjualan Spare Part pada AHASS Nur Andhita Grogol. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 5(12).

- Heryadi, Y., & Irwansyah, E. (2020). *Deep Learning: Aplikasinya di Bidang Geospasial*. AWI Technology Press.
- IBRAHIM, N., SA'IDAH, S., HIDAYAT, B., & DARANA, S. (2022). Klasifikasi Grade Telur Ayam Negeri secara non-Invasive menggunakan Convolutional Neural Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(2), 297. <https://doi.org/10.26760/elkomika.v10i2.297>
- Indriani, S. D. D., Sinaga, E. J. A., Oktavia, G., Syahputra, H., & Ramadhani, F. (2024). Identifikasi Tanda Tangan Dengan Menggunakan Metode Convolution Neural Network (CNN). *J-INTECH*, 12(1), 138–147. <https://doi.org/10.32664/j-intech.v12i1.1273>
- Jaya, H., Sabran, S., Idris, Muh. M., Djawad, Y. A., Ilham, A., & Ahmar, A. S. (2018). *KECERDASAN BUATAN*. Fakultas MIPA Universitas Negeri Makassar.
- Kamath, U., Liu, J., & Whitaker, J. (2019). *Deep learning for NLP and speech recognition*. Springer. <https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=2544726>
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- Marcella, D., Yohannes, Y., & Devella, S. (2022). Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-19. *Jurnal Algoritme*, 3(1), 60–70. <https://doi.org/10.35957/algoritme.v3i1.3331>
- Naufal, M. F. (2021). Analisis Perbandingan Algoritma SVM, KNN, dan CNN untuk Klasifikasi Citra Cuaca. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 8(2), 311–318. <https://doi.org/10.25126/jtiik.2021824553>
- Naufal, M. F., & Kusuma, S. F. (2022). *Weather image classification using convolutional neural network with transfer learning*. 050004. <https://doi.org/10.1063/5.0080195>
- Rizal, F., Hasyim, F., Malik, K., & Yudistira, Y. (2022). Implementasi Algoritma Convolutional Neural Networks (CNN) Untuk Klasifikasi Batik. *COREAI: Jurnal Kecerdasan Buatan, Komputasi Dan Teknologi Informasi*, 2(2), 40–47. <https://doi.org/10.33650/coreai.v2i2.3365>
- Sewak, M., Karim, Md. R., & Pujari, P. (2018). *Practical Convolutional Neural Networks: Implement advanced deep learning models using Python*. Packt Publishing.
- Sharma, A., & Ismail, Z. S. (2022). Weather Classification Model Performance: Using CNN, Keras-Tensor Flow. *ITM Web of Conferences*, 42, 01006. <https://doi.org/10.1051/itmconf/20224201006>
- Suryanto. (2014). *Artificial Intelligence : Searching, Reasoning, Planning, Dan Learning*. Informatika.
- Suyanto, Ramadhani, K. N., & Mandala, S. (2019). *Deep learning : modernisasi machine learning untuk big data*. Penerbit Informatika Bandung.
- Wibawa, M., Sunarmi, S., & Soewarlan, S. (2024). Transformasi Digital Sebagai Strategi Kenusantaraan Warisan Budaya: Studi AI Pada Kereta Kencana Paksi Naga Liman. *MAVIS : Jurnal Desain Komunikasi Visual*, 6(01), 1–11. <https://doi.org/10.32664/mavis.v6i01.1187>