

Klasifikasi Kategori Cuaca Berdasarkan Citra Menggunakan VGG-16

Sugeng Riyadi^{1)*}, Doughlas Pardede²⁾, Raja Nasrul Fuad³⁾

^{1,2,3)} Universitas Deli Sumatera

¹⁾ adhie.ogenk@gmail.com, ²⁾ doug.pardede@gmail.com, ³⁾ bung.fuad@gmail.com

Received: 15 September 2024

Accepted: 23 September 2024

Published: 25 September 2024



[*adhie.ogenk@gmail.com](mailto:adhie.ogenk@gmail.com)

Kata Kunci: Convolutional Neural Network (CNN), VGG-16, Klasifikasi Cuaca, Citra Digital

DSI: Jurnal Data Science Indonesia is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).

Abstrak : Penelitian ini bertujuan untuk mengklasifikasikan kondisi cuaca seperti Berawan, Cerah, dan Terbit, menggunakan citra digital dengan pendekatan otomatis berbasis Convolutional Neural Network (CNN). Arsitektur VGG-16 dipilih karena kemampuannya dalam mengekstraksi fitur detail melalui lapisan konvolusional bertingkat. Dataset yang digunakan berisi 910 citra, dibagi menjadi tiga kategori, dan diolah menggunakan VGG-16 untuk menghasilkan vektor fitur berdimensi 4096. Klasifikasi dilakukan dengan jaringan saraf tiruan yang memiliki tiga lapisan tersembunyi, dan evaluasi model menggunakan metode 10-fold cross-validation. Metrik yang digunakan untuk menilai kinerja model adalah akurasi, presisi, dan recall. Hasil penelitian menunjukkan bahwa VGG-16 mampu mengklasifikasikan citra dengan akurasi sebesar 96,48%, dengan performa terbaik pada kelas Berawan, Cerah, dan Terbit, yaitu masing-masing 96%, 95,5%, dan 97,2%. Meskipun model menunjukkan akurasi tinggi, tantangan masih ada dalam membedakan citra dengan fitur visual yang serupa, seperti intensitas cahaya dan formasi awan. Kesimpulannya, VGG-16 efektif dalam klasifikasi kondisi cuaca berbasis citra digital, namun memerlukan pengembangan lebih lanjut untuk mengatasi kesalahan klasifikasi akibat kemiripan visual antara kategori cuaca.

PENDAHULUAN

Cuaca sering kali dapat diamati dari kondisi langit, dengan kategori umum seperti cerah, berawan, dan terbit [1]. Namun, ketiga kondisi ini memiliki ciri yang mirip, seperti adanya cahaya matahari dan formasi awan, yang sering kali menyebabkan kekeliruan dalam mengidentifikasi secara akurat [1]. Kesalahan dalam pengkategorian ini dapat mengakibatkan interpretasi cuaca yang tidak tepat, terutama dalam konteks yang memerlukan pemantauan cuaca secara akurat [2]. Untuk mengatasi masalah ini, penggunaan teknologi computer vision yang dipadukan dengan machine learning dapat memungkinkan pengembangan model otomatis yang mampu mengklasifikasikan kondisi langit dengan lebih presisi, sehingga memberikan hasil yang lebih akurat dan efisien dalam pemantauan cuaca [2].

Image recognition merupakan salah satu cabang dari computer vision yang fokus pada pengenalan pola atau fitur dalam citra, sehingga sangat sesuai untuk digunakan dalam klasifikasi kondisi cuaca berbasis citra digital [2]. Teknologi ini telah terbukti efektif dan banyak digunakan dalam berbagai kasus klasifikasi citra, seperti pengenalan wajah untuk keamanan [3], identifikasi objek dalam kendaraan otonom [4], serta klasifikasi citra medis untuk diagnosis penyakit [5]. Berdasarkan bukti luasnya aplikasi image recognition dalam berbagai domain tersebut, penulis tertarik untuk memanfaatkan teknologi ini dalam penyelesaian masalah penelitian yang bertujuan mengklasifikasikan kondisi cuaca seperti berawan, cerah, dan terbit secara otomatis dan akurat.

Dalam image recognition, ekstraksi fitur memegang peranan penting dalam proses klasifikasi karena merupakan inti dari seluruh proses yang memungkinkan model mengenali pola atau karakteristik penting dalam citra [6]. Kualitas ekstraksi fitur yang baik sangat menentukan akurasi model klasifikasi, karena fitur yang diekstraksi dengan tepat akan memberikan representasi yang lebih akurat terhadap citra, sehingga

meningkatkan kemampuan model dalam mengenali pola [7]. Salah satu algoritma yang populer dan sering digunakan dalam image recognition adalah Convolutional Neural Network (CNN). Keunggulan utama CNN terletak pada arsitekturnya yang dinamis dan kemampuannya dalam mengekstraksi fitur secara otomatis tanpa memerlukan proses pre-processing yang kompleks terhadap citra yang diolah [8]. Hal ini membuat CNN sangat efektif dan efisien dalam menangani masalah pengenalan pola citra dengan tingkat akurasi yang tinggi [9].

VGG-16 merupakan salah satu bentuk arsitektur dalam Convolutional Neural Networks (CNN) yang dirancang dengan susunan lapisan konvolusi bertingkat dan filter berukuran kecil (3x3), serta beberapa lapisan pooling yang secara bertahap menyederhanakan representasi data [10]. Kelebihan utama dari arsitektur VGG-16 dibandingkan arsitektur standard CNN terletak pada kedalamannya, dengan 16 lapisan yang memungkinkan ekstraksi fitur lebih mendetail dan kompleks, sehingga meningkatkan kemampuan model dalam mengenali pola-pola halus pada citra [11]. VGG-16 telah digunakan secara luas dalam berbagai penelitian, seperti klasifikasi gambar medis untuk diagnosis penyakit [12], identifikasi objek dalam sistem pengawasan visual [13], serta pengenalan wajah pada aplikasi keamanan digital [14]. Berdasarkan bukti keberhasilan pengaplikasian VGG-16 dalam berbagai kasus klasifikasi citra tersebut, penulis memilih untuk menerapkan arsitektur ini dalam model klasifikasi kondisi cuaca pada penelitian ini guna mendapatkan hasil yang lebih presisi dan akurat.

Penelitian ini bertujuan untuk melakukan klasifikasi kondisi cuaca seperti berawan, cerah, dan terbit berdasarkan inputan citra digital. Dengan menggunakan dataset citra tersebut, model VGG-16 diimplementasikan untuk mengekstraksi fitur dari setiap citra secara mendetail, guna menangkap karakteristik visual yang relevan dengan kondisi cuaca. Untuk proses klasifikasi, digunakan algoritma neural network yang bertugas mengelompokkan citra ke dalam kategori "Berawan", "Cerah", dan "Terbit." Evaluasi model dilakukan menggunakan metode 10-fold cross validation, yang diukur dengan metrik akurasi, presisi, dan recall untuk memastikan kinerja model dalam mengklasifikasikan kondisi cuaca secara akurat dan andal.

TINJAUAN LITERATUR

Pengaplikasian image recognition telah terbukti efektif dalam berbagai kasus klasifikasi citra di sejumlah bidang. Pertama, penelitian dalam medis menggunakan image recognition untuk mendeteksi dan mendiagnosis penyakit dari citra X-ray atau MRI, seperti klasifikasi kanker payudara [15] atau pneumonia [16], di mana akurasi model mampu mencapai tingkat tinggi berkat kemampuan ekstraksi fitur citra yang detail. Kedua, dalam otomotif, image recognition digunakan untuk klasifikasi objek jalan pada kendaraan otonom [17], yang memungkinkan mobil mengenali dan mengklasifikasikan kendaraan lain, pejalan kaki, dan rambu lalu lintas dengan cepat dan presisi. Ketiga, dalam bidang keamanan, teknologi ini diterapkan pada sistem pengenalan wajah untuk verifikasi identitas [18], yang membantu meningkatkan keamanan digital dengan akurasi tinggi dalam mengenali pola wajah manusia. Berdasarkan keberhasilan aplikasi tersebut, image recognition terbukti layak digunakan sebagai metode dalam pemecahan masalah penelitian ini, yaitu mengklasifikasikan kondisi cuaca seperti berawan, cerah, dan terbit dari citra digital.

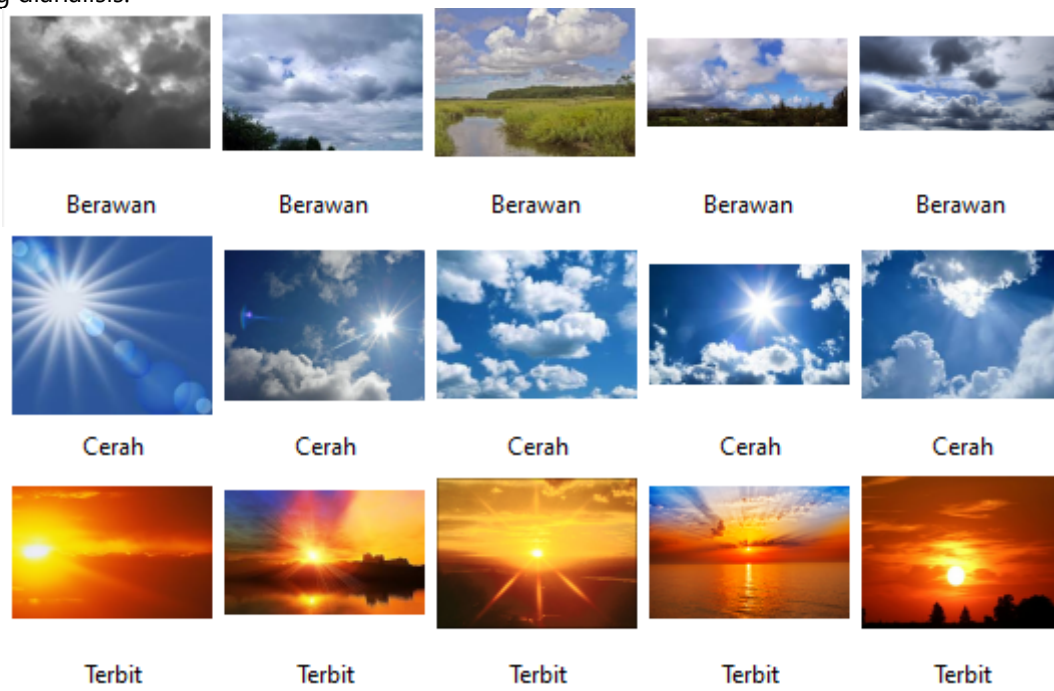
VGG-16 bekerja dengan cara mengolah citra melalui rangkaian lapisan konvolusi bertingkat yang menggunakan filter berukuran kecil (3x3) untuk mengekstraksi fitur dari citra dengan detail yang sangat tinggi [19]. Setelah ekstraksi fitur, informasi yang dihasilkan diproses melalui beberapa lapisan pooling dan fully connected untuk menghasilkan representasi yang dapat digunakan dalam klasifikasi [20]. Dalam konteks klasifikasi cuaca, VGG-16 telah diaplikasikan secara efektif dalam beberapa studi: pertama, pada klasifikasi citra satelit untuk mendeteksi kondisi atmosfer seperti awan dan sinar matahari [21]; kedua, dalam sistem pengenalan kondisi jalan berdasarkan citra cuaca untuk perencanaan dan manajemen lalu lintas [22]; dan ketiga, dalam aplikasi pengawasan lingkungan yang memantau perubahan kondisi cuaca untuk analisis jangka panjang [23]. Berdasarkan keberhasilan VGG-16 dalam ekstraksi fitur pada berbagai kasus klasifikasi cuaca tersebut, metode ini dipilih untuk ekstraksi fitur citra dalam penelitian ini, yang bertujuan untuk mengklasifikasikan citra cuaca ke dalam kategori "Berawan," "Cerah," dan "Terbit".

Hasil ekstraksi fitur dari VGG-16 dapat dimanfaatkan sebagai bentuk transfer learning dengan digunakan sebagai input dataset untuk algoritma klasifikasi lainnya [24]. Dalam konteks ini, VGG-16 yang telah dilatih pada dataset besar seperti ImageNet menyediakan fitur yang kaya untuk kemudian digunakan dalam model

klasifikasi yang lebih spesifik [25]. Beberapa penelitian telah menunjukkan keberhasilan kombinasi VGG-16 dan neural network dalam transfer learning, seperti dalam studi yang menggunakan VGG-16 untuk ekstraksi fitur dalam klasifikasi citra medis yang diinputkan ke dalam neural network untuk diagnosis penyakit [26], penelitian lain yang memanfaatkan VGG-16 untuk ekstraksi fitur dalam pengenalan objek pada citra satelit yang diklasifikasikan menggunakan neural network untuk manajemen bencana [27], dan sebuah studi yang mengaplikasikan VGG-16 untuk ekstraksi fitur dalam sistem pengenalan wajah yang dikombinasikan dengan neural network untuk identifikasi individu [28]. Berdasarkan bukti keberhasilan kombinasi ini, penelitian saya akan menerapkan metode serupa, yaitu menggunakan VGG-16 untuk ekstraksi fitur citra yang kemudian diklasifikasikan dengan neural network untuk menentukan kondisi cuaca berdasarkan citra yang diinputkan.

METODE PENELITIAN

Penelitian ini menggunakan dataset yang diambil dari website kaggle.com, yang terdiri dari total 910 citra digital yang dikelompokkan ke dalam tiga folder: Berawan, Cerah, dan Terbit. Folder Berawan mengandung 300 citra digital, folder Cerah terdiri dari 253 citra digital, dan folder Terbit memuat 357 citra digital. Distribusi citra dalam folder ini dirancang untuk mencerminkan variasi kondisi cuaca yang berbeda. Gambar 1 memperlihatkan sampel dataset yang digunakan dalam penelitian ini, memberikan gambaran tentang tipe citra yang dianalisis.



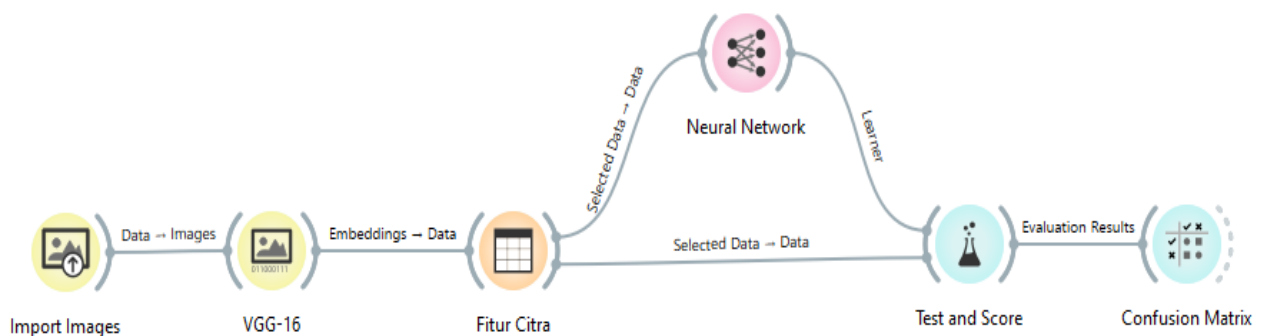
Gambar 1 Sampel Dataset

Dalam penelitian ini, fitur dari citra pada masing-masing folder diekstraksi menggunakan model VGG-16, yang menghasilkan 4096 fitur untuk setiap citra. Proses ekstraksi fitur dimulai dengan menginput citra ke dalam jaringan saraf konvolusional VGG-16, yang telah dilatih pada dataset besar untuk mendeteksi pola-pola visual. Setiap citra dari folder Berawan, Cerah, dan Terbit diproses melalui lapisan-lapisan konvolusional dan lapisan penuh VGG-16 untuk mengekstrak representasi fitur tingkat tinggi. Hasil dari proses ini adalah vektor fitur berdimensi 4096 untuk setiap citra, yang kemudian digunakan untuk analisis lebih lanjut.

Setelah proses ekstraksi fitur selesai, hasil ekstraksi disimpan dalam sebuah tabel yang berfungsi sebagai dataset untuk proses klasifikasi selanjutnya. Dataset ini berisi vektor fitur berdimensi 4096 untuk setiap citra dari masing-masing folder. Untuk tahap klasifikasi, digunakan algoritma jaringan saraf tiruan dengan tiga hidden layer, masing-masing terdiri dari 100 neuron. Fungsi aktivasi ReLU diterapkan pada setiap neuron untuk meningkatkan non-linearitas model, sedangkan fungsi optimasi Adam digunakan untuk memperbaiki proses pelatihan dengan menyesuaikan kecepatan pembelajaran secara adaptif. Metode ini bertujuan untuk memaksimalkan akurasi dalam mengklasifikasikan citra berdasarkan fitur yang diekstraksi.

Dalam membangun model, penelitian ini memanfaatkan aplikasi Orange Data Mining dengan tambahan Add-On Image Analytic. Widget Import Image dari Image Analytic digunakan untuk memuat citra digital yang akan diproses ke dalam aplikasi. Selanjutnya, widget Image Embedding diterapkan untuk mengekstraksi fitur dari citra menggunakan arsitektur VGG-16. Proses ini menghasilkan vektor fitur berdimensi 4096 untuk setiap citra, yang kemudian disimpan dalam tabel dan digunakan sebagai dataset untuk proses klasifikasi. Penggunaan Orange Data Mining dan Add-On Image Analytic memungkinkan integrasi yang efisien dari tahap pemrosesan citra hingga ekstraksi fitur dan klasifikasi.

Penelitian ini juga menggunakan learner Neural Network untuk melakukan proses klasifikasi berdasarkan hasil ekstraksi fitur dari VGG-16. Kinerja model dievaluasi menggunakan widget Test & Score yang memanfaatkan 10-fold cross-validation untuk memastikan keakuratan dan generalisasi model. Widget ini juga menampilkan nilai akurasi, presisi, dan recall dari model yang dibangun. Gambar 2 memperlihatkan rancangan arsitektur model yang dikembangkan, memberikan gambaran visual tentang struktur dan komponen utama dari model neural network yang digunakan.



Gambar 2 Arsitektur Model

Evaluasi kinerja dilakukan menggunakan widget "Test & Score," yang mengukur performa model berdasarkan metrik akurasi, presisi, dan recall. Pendekatan ini memungkinkan analisis komprehensif terhadap efektivitas berbagai konfigurasi dan fungsi aktivasi dalam memprediksi risiko penyakit jantung. Akurasi mengukur proporsi prediksi yang benar dibandingkan dengan total prediksi, dihitung dengan formula (1) [29]:

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

Presisi mengukur proporsi prediksi positif yang benar dibandingkan dengan total prediksi positif, dengan formula (2) [30]:

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

penting untuk menilai sejauh mana model dapat mengidentifikasi kasus positif dengan benar.

Recall, atau sensitivitas, mengukur proporsi kasus positif yang benar-benar terdeteksi dibandingkan dengan total kasus positif yang sebenarnya, dihitung dengan formula (3) [29]:

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

Ketiga metrik ini memberikan gambaran komprehensif tentang performa model dalam mengklasifikasikan risiko penyakit jantung dan membantu dalam memilih model yang paling efektif.

HASIL PENELITIAN

Gambar 3 menunjukkan confusion matrix dari model klasifikasi yang dibangun. Pada baris "Actual Berawan", dari 300 citra berawan yang sebenarnya, model mengklasifikasikan 288 citra dengan benar sebagai Berawan, sementara 8 citra salah diklasifikasikan sebagai Cerah dan 4 citra salah diklasifikasikan sebagai Terbit. Pada baris "Actual Cerah", dari 253 citra cerah, 243 diklasifikasikan dengan benar, sedangkan 8 citra salah diklasifikasikan sebagai Berawan dan 2 citra sebagai Terbit. Pada baris "Actual Terbit", dari 357 citra

Terbit, model berhasil mengklasifikasikan 347 citra dengan benar, sementara 3 citra salah diklasifikasikan sebagai Berawan dan 7 citra sebagai Cerah. Hasil ini mencerminkan performa model yang baik dalam mengklasifikasikan citra ke dalam kategori yang benar, dengan sebagian besar prediksi sesuai dengan kondisi sebenarnya.

		Predicted			Σ
		Berawan	Cerah	Terbit	
Actual	Berawan	288	8	4	300
	Cerah	8	243	2	253
	Terbit	3	7	347	357
Σ		299	258	353	910

Gambar 3 Hasil Confusion Matrix

Pada kelas Berawan, dari total 300 citra yang sebenarnya berawan, model berhasil mengklasifikasikan 288 citra dengan benar. Namun, terdapat 12 citra yang diklasifikasikan secara salah, di mana 8 citra salah diklasifikasikan sebagai Cerah, dan 4 citra diklasifikasikan sebagai Terbit. Kesalahan prediksi ini mungkin disebabkan oleh adanya kemiripan fitur visual antara kondisi berawan dan cerah atau Terbit, yang mengakibatkan model kesulitan dalam membedakan karakteristik spesifik dari citra berawan. Hal ini menunjukkan bahwa meskipun model memiliki performa yang baik secara keseluruhan, masih ada beberapa kasus di mana fitur yang diekstraksi tidak cukup untuk menangkap perbedaan mendasar antara citra berawan dan kelas lainnya.

Pada kelas Berawan, dari total 300 citra yang sebenarnya berawan, model berhasil mengklasifikasikan 288 citra dengan benar. Namun, terdapat 12 citra yang diklasifikasikan secara salah, di mana 8 citra salah diklasifikasikan sebagai Cerah, dan 4 citra diklasifikasikan sebagai Terbit. Kesalahan prediksi ini mungkin disebabkan oleh adanya kemiripan fitur visual antara kondisi berawan dan cerah atau Terbit, yang mengakibatkan model kesulitan dalam membedakan karakteristik spesifik dari citra berawan. Hal ini menunjukkan bahwa meskipun model memiliki performa yang baik secara keseluruhan, masih ada beberapa kasus di mana fitur yang diekstraksi tidak cukup untuk menangkap perbedaan mendasar antara citra berawan dan kelas lainnya.

Pada kelas Terbit, dari total 357 citra yang sebenarnya Terbit, model berhasil mengklasifikasikan 347 citra dengan benar, tetapi ada 10 citra yang salah diprediksi. Sebanyak 3 citra salah diklasifikasikan sebagai Berawan, dan 7 citra diklasifikasikan sebagai Cerah. Kesalahan ini bisa disebabkan oleh kemiripan fitur visual antara citra Terbit dengan citra cerah dan berawan, terutama dalam hal intensitas cahaya yang terekam dalam gambar. Citra Terbit yang salah diklasifikasikan sebagai cerah mungkin memiliki kondisi pencahayaan yang tidak terlalu intens, sehingga dianggap lebih mirip dengan kondisi cerah. Sedangkan citra yang diklasifikasikan sebagai berawan kemungkinan memiliki elemen visual tertentu, seperti bayangan atau awan tipis, yang menyebabkan model salah mendeteksi sebagai kondisi berawan. Hal ini mengindikasikan bahwa meskipun model cukup akurat dalam mengenali citra Terbit, ada beberapa kesalahan yang menunjukkan tantangan dalam membedakan intensitas cahaya dan pola cuaca di antara ketiga kelas.

Dari tabel confusion matrix yang ditunjukkan pada Gambar 2, diperoleh metrik evaluasi akurasi, presisi, dan recall untuk model Neural Network. Berdasarkan data di dalam tabel, akurasi yang diperoleh adalah 0,9648, presisi 0,9650, dan recall 0,9648.

Akurasi dihitung dengan membagi jumlah prediksi yang benar dengan total prediksi yang dilakukan. Dalam hal ini, jumlah prediksi yang benar adalah 288 (Berawan) + 243 (Cerah) + 347 (Terbit) = 878, sedangkan total prediksi adalah 910 (jumlah total data). Maka, akurasi dihitung sebagai:

$$Akurasi = \frac{878}{910} = 0.9648$$

Presisi dihitung dengan membagi jumlah prediksi benar pada setiap kelas dengan total prediksi yang dibuat untuk kelas tersebut. Untuk kelas Berawan, diperoleh True Positive sebesar 288 dan False Positive

sebesar 8. Untuk kelas Cerah, diperoleh True Positive sebesar 243 dan False Positive sebesar 8. Sedangkan untuk kelas Terbit diperoleh True Positive sebesar 347 dan False Positive sebesar 4. Dengan menggunakan nilai-nilai ini, presisi dihitung dengan:

$$Presisi_{Berawan} = \frac{288}{288+8} = 0.9635$$

$$Presisi_{Cerah} = \frac{243}{243+8} = 0.9419$$

$$Presisi_{Terbit} = \frac{347}{347+4} = 0.9830$$

sehingga diperoleh nilai presisi rata-rata sebesar:

$$Presisi = \frac{0.9635+0.9419+0.983}{3} = 0.965$$

Recall dihitung dengan membagi jumlah prediksi benar pada setiap kelas dengan total data aktual untuk kelas tersebut. Untuk kelas Berawan, diperoleh True Positive sebesar 288 dan False Positive sebesar 12. Untuk kelas Cerah, diperoleh True Positive sebesar 243 dan False Positive sebesar 10. Sedangkan untuk kelas Terbit diperoleh True Positive sebesar 347 dan False Positive sebesar 10. Dengan menggunakan nilai-nilai ini, recall dihitung dengan:

$$Recall_{Berawan} = \frac{288}{288+12} = 0.96$$

$$Recall_{Cerah} = \frac{243}{243+10} = 0.9604$$

$$Recall_{Terbit} = \frac{347}{347+10} = 0.972$$

sehingga diperoleh nilai recall rata-rata sebesar:

$$Recall = \frac{0.96+0.9604+0.972}{3} = 0.9648$$

PEMBAHASAN

Berdasarkan hasil penelitian yang ditunjukkan pada Gambar 3, model klasifikasi yang dibangun menunjukkan performa yang baik dalam membedakan citra Berawan, Cerah, dan Terbit. Pada kelas Berawan, model mampu mengklasifikasikan 288 dari 300 citra dengan benar, meskipun ada 12 citra yang salah diklasifikasikan sebagai Cerah (8 citra) dan Terbit (4 citra). Kesalahan prediksi ini kemungkinan disebabkan oleh kemiripan fitur visual antara citra berawan dengan kondisi cerah dan Terbit. Faktor seperti variasi pencahayaan dan bentuk awan dapat mempengaruhi hasil klasifikasi, mengingat ciri-ciri visual antara ketiga kondisi cuaca tersebut mungkin saling tumpang tindih.

Untuk kelas Cerah, model berhasil mengklasifikasikan 243 dari 253 citra dengan benar, tetapi terdapat 10 citra yang salah diprediksi, di mana 8 citra salah diklasifikasikan sebagai Berawan dan 2 citra diklasifikasikan sebagai Terbit. Kemiripan fitur visual antara kondisi cerah dengan berawan mungkin disebabkan oleh elemen visual seperti kehadiran awan tipis atau perbedaan intensitas cahaya yang tidak terlalu signifikan. Kesalahan klasifikasi ini menunjukkan bahwa meskipun model cukup baik dalam mendeteksi citra cerah, terdapat beberapa citra yang memerlukan fitur lebih spesifik untuk menghindari kesalahan prediksi.

Pada kelas Terbit, model memiliki performa yang sangat baik dengan mengklasifikasikan 347 dari 357 citra dengan benar. Namun, terdapat 10 citra yang salah diprediksi, dengan 3 citra salah diklasifikasikan sebagai Berawan dan 7 citra sebagai Cerah. Kesalahan ini mungkin disebabkan oleh pencahayaan yang lebih rendah pada citra Terbit, sehingga model keliru menganggapnya sebagai cerah atau berawan. Selain itu, kesamaan pola visual antara kondisi cerah dan Terbit dalam hal intensitas cahaya juga dapat menjadi faktor penyebab kesalahan.

Secara keseluruhan, berdasarkan confusion matrix, model ini memiliki akurasi sebesar 0,9648, yang berarti model mampu mengklasifikasikan 96,48% citra dengan benar. Presisi rata-rata model adalah 0,9650, menunjukkan bahwa sebagian besar prediksi untuk masing-masing kelas cukup akurat. Recall rata-rata sebesar 0,9648 juga mencerminkan bahwa model mampu mengidentifikasi citra yang benar dengan sangat baik. Meskipun demikian, beberapa kesalahan klasifikasi pada citra tertentu menunjukkan bahwa ada ruang

untuk peningkatan, terutama dalam membedakan fitur visual yang lebih halus antara kondisi cuaca yang berbeda.

KESIMPULAN

Berdasarkan hasil penelitian ini, model klasifikasi citra cuaca menggunakan Neural Network dengan arsitektur VGG-16 sebagai ekstraktor fitur menunjukkan performa yang baik, dengan akurasi sebesar 96,48%, presisi 96,50%, dan recall 96,48%. Model mampu mengklasifikasikan mayoritas citra dalam kategori Berawan, Cerah, dan Terbit dengan tingkat kesalahan yang relatif rendah, sebagaimana ditunjukkan pada confusion matrix. Meskipun demikian, terdapat beberapa kesalahan klasifikasi, terutama antara citra berawan dan cerah serta antara Terbit dan cerah, yang kemungkinan disebabkan oleh kemiripan fitur visual seperti pencahayaan dan pola awan tipis. Kesalahan tersebut mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan fitur-fitur yang lebih halus antara kondisi cuaca yang berbeda. Secara keseluruhan, penelitian ini membuktikan bahwa metode klasifikasi berbasis Neural Network dengan ekstraksi fitur menggunakan VGG-16 cukup efektif dalam tugas klasifikasi citra cuaca, namun dapat ditingkatkan lebih lanjut dengan optimasi yang lebih mendalam terhadap fitur-fitur visual yang digunakan.

REFERENCES

- [1] M. Fathi, M. Haghi Kashani, S. M. Jameii, and E. Mahdipour, "Big Data Analytics in Weather Forecasting: A Systematic Review," *Arch. Comput. Methods Eng.*, vol. 29, no. 2, pp. 1247–1275, 2022, doi: 10.1007/s11831-021-09616-4.
- [2] M. F. Naufal and S. F. Kusuma, "Weather image classification using convolutional neural network with transfer learning," in *AIP Conference Proceedings*, 2022, p. 050004. doi: 10.1063/5.0080195.
- [3] Z. Wang, X. Zhang, P. Yu, W. Duan, D. Zhu, and N. Cao, "A new face recognition method for intelligent security," *Appl. Sci.*, vol. 10, no. 3, 2020, doi: 10.3390/app10030852.
- [4] L. Peng, H. Wang, and J. Li, "Uncertainty Evaluation of Object Detection Algorithms for Autonomous Vehicles," *Automot. Innov.*, vol. 4, no. 3, pp. 241–252, 2021, doi: 10.1007/s42154-021-00154-0.
- [5] H. E. Kim, A. Cosa-Linan, N. Santhanam, M. Jannesari, M. E. Maros, and T. Ganslandt, "Transfer learning for medical image classification: a literature review," *BMC Med. Imaging*, vol. 22, no. 1, pp. 1–13, 2022, doi: 10.1186/s12880-022-00793-7.
- [6] A. Ichsan, S. Riyadi, and D. Pardede, "Analysis of Logistic Regression Regularization in Wild Elephant Classification with VGG-16 Feature Extraction," *J. Comput. Networks, Archit. High Perform. Comput.*, vol. 6, no. 2, pp. 783–793, Apr. 2024, doi: 10.47709/cnahpc.v6i2.3789.
- [7] Y. Franciska, T. S. Gunawan, and B. H. Hayadi, "Combination Of SqueezeNet And Multilayer Backpropagation Algorithm In Hanacaraka Script Recognition," *2nd Int. Conf. Information Sci. Technol. Innov.*, vol. 2, no. 2(1), pp. 163–170, 2023, [Online]. Available: <https://prosidings-icostec.respati.ac.id/index.php/icostec/article/view/51/51>
- [8] M. Wahyuni, R. Rosnelly, and Wanayumini, "Combination of Pre-Trained CNN Model and Machine Learning Algorithm on Pekalongan Batik Motif Classification," *Int. Conf. Inf. Sci. Technol. Innov.*, vol. 2, no. 1, pp. 6–10, Mar. 2023, doi: 10.35842/icostec.v2i1.28.
- [9] S. Mandasari, D. Irfan, W. Wanayumini, and R. Rosnelly, "COMPARISON OF SGD, ADADELTA, ADAM OPTIMIZATION IN GENDER CLASSIFICATION USING CNN," *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 9, no. 3, pp. 345–354, Jun. 2023, doi: 10.33330/jurteksi.v9i3.2067.
- [10] J. Kusuma, Rubianto, R. Rosnelly, Hartono, and B. H. Hayadi, "Klasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron," *J. Appl. Comput. Sci. Technol.*, vol. 4, no. 1, pp. 1–6, Jun. 2023, doi: 10.52158/jacost.v4i1.484.
- [11] N. Habib, M. M. Hasan, M. M. Reza, and M. M. Rahman, "Ensemble of CheXNet and VGG-19 Feature Extractor with Random Forest Classifier for Pediatric Pneumonia Detection," *SN Comput. Sci.*, vol. 1, no. 6, 2020, doi: 10.1007/s42979-020-00373-y.
- [12] Z. P. Jiang, Y. Y. Liu, Z. E. Shao, and K. W. Huang, "An improved VGG16 model for pneumonia image classification," *Appl. Sci.*, vol. 11, no. 23, 2021, doi: 10.3390/app112311185.

- [13] M. F. NURYASIN, C. MACHBUB, and L. YULIANTI, "Kombinasi Deteksi Objek, Pengenalan Wajah dan Perilaku Anomali menggunakan State Machine untuk Kamera Pengawas," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 1, p. 86, 2023, doi: 10.26760/elkomika.v11i1.86.
- [14] B. Koodalsamy, M. B. Veerayan, and V. Narayanasamy, "Face Recognition using Deep Learning," *E3S Web Conf.*, vol. 387, no. 01, pp. 1–7, 2023, doi: 10.1051/e3sconf/202338705001.
- [15] Z. Liu, J. Peng, X. Guo, S. Chen, and L. Liu, "Breast cancer classification method based on improved VGG16 using mammography images," *J. Radiat. Res. Appl. Sci.*, vol. 17, no. 2, p. 100885, 2024, doi: 10.1016/j.jrras.2024.100885.
- [16] Dr. Sunil L. Bangare, Hrushikesh S. Rajankar, Pavan S. Patil, Karan V. Nakum, and Gopal S. Paraskar, "Pneumonia Detection and Classification using CNN and VGG16," *Int. J. Adv. Res. Sci. Commun. Technol.*, no. May, pp. 771–779, 2022, doi: 10.48175/ijarsct-3851.
- [17] Q. Wu, X. Li, K. Wang, and H. Bilal, "Regional feature fusion for on-road detection of objects using camera and 3D-LiDAR in high-speed autonomous vehicles," *Soft Comput.*, vol. 27, no. 23, pp. 18195–18213, 2023, doi: 10.1007/s00500-023-09278-3.
- [18] K. H. Teoh, R. C. Ismail, S. Z. M. Naziri, R. Hussin, M. N. M. Isa, and M. S. S. M. Basir, "Face Recognition and Identification using Deep Learning Approach," *J. Phys. Conf. Ser.*, vol. 1755, no. 1, 2021, doi: 10.1088/1742-6596/1755/1/012006.
- [19] R. Rismiyati and A. Luthfiarta, "VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification," *Telematika*, vol. 18, no. 1, p. 37, 2021, doi: 10.31315/telematika.v18i1.4025.
- [20] J. N. Mogan, C. P. Lee, K. M. Lim, and K. S. Muthu, "VGG16-MLP: Gait Recognition with Fine-Tuned VGG-16 and Multilayer Perceptron," *Appl. Sci.*, vol. 12, no. 15, pp. 1–12, 2022, [Online]. Available: <https://www.mdpi.com/2076-3417/12/15/7639>
- [21] M. Guzel, M. Kalkan, E. Bostanci, K. Acici, and T. Asuroglu, "Cloud type classification using deep learning with cloud images," *PeerJ Comput. Sci.*, vol. 10, 2024, doi: 10.7717/peerj-cs.1779.
- [22] M. Abouelyazid, "Comparative Evaluation of VGG-16 and U-Net Architectures for Road Segmentation," *Eig. Rev. Sci. Technol.*, vol. 5, no. 1, pp. 75–91, 2022.
- [23] S. Mittal and O. P. Sangwan, "Classifying Weather Images using Deep Neural Networks for Large Scale Datasets," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 1, pp. 337–343, 2023, doi: 10.14569/IJACSA.2023.0140136.
- [24] J. Pardede, B. Sitohang, S. Akbar, and M. L. Khodra, "Implementation of Transfer Learning Using VGG16 on Fruit Ripeness Detection," *Int. J. Intell. Syst. Appl.*, vol. 13, no. 2, pp. 52–61, Apr. 2021, doi: 10.5815/ijisa.2021.02.04.
- [25] A. A. Siddiqui and C. Kayte, "Transfer Learning for Mosquito Classification Using VGG16," no. M1, Atlantis Press International BV, 2023, pp. 471–484. doi: 10.2991/978-94-6463-196-8_36.
- [26] S. Sharma, K. Guleria, S. Tiwari, and S. Kumar, "A deep learning based convolutional neural network model with VGG16 feature extractor for the detection of Alzheimer Disease using MRI scans," *Meas. Sensors*, vol. 24, no. October, p. 100506, 2022, doi: 10.1016/j.measen.2022.100506.
- [27] S. Kaur *et al.*, "Transfer Learning-Based Automatic Hurricane Damage Detection Using Satellite Images," *Electron.*, vol. 11, no. 9, 2022, doi: 10.3390/electronics11091448.
- [28] A. K. Dubey and V. Jain, "Automatic facial recognition using VGG16 based transfer learning model," *J. Inf. Optim. Sci.*, vol. 41, no. 7, pp. 1589–1596, 2020, doi: 10.1080/02522667.2020.1809126.
- [29] D. Pardede, I. Firmansyah, M. Handayani, M. Riandini, and R. Rosnelly, "Comparison Of Multilayer Perceptron's Activation And Optimization Functions In Classification Of Covid-19 Patients," *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 8, no. 3, pp. 271–278, Aug. 2022, doi: 10.33330/jurteksiv8i3.1482.
- [30] I. Firmansyah, J. T. Samudra, D. Pardede, and Z. Situmorang, "Comparison Of Random Forest And Logistic Regression In The Classification Of Covid-19 Sufferers Based On Symptoms," *J. Sci. Soc. Res.*, vol. 5, no. 3, p. 595, Oct. 2022, doi: 10.54314/jssr.v5i3.994.