

KLASIFIKASI KONDISI CUACA JALAN RAYA BERBASIS CITRA CCTV MENGGUNAKAN VISION TRANSFORMER

Gilang Andhika Buwana¹, Mohamad Nurkamal Fauzan²

^{1,2}Teknik Informatika, Fakultas Vokasi, Universitas Logistik Dan Bisnis Internasional
email: ¹fandhika.bwn@gmail.com, ²m.nurkamal.f@ulbi.ac.id

Abstrak Kondisi cuaca, khususnya hujan, merupakan faktor penting yang memengaruhi keselamatan dan kelancaran lalu lintas jalan raya. Informasi cuaca yang tersedia saat ini umumnya bersifat regional dan belum sepenuhnya merepresentasikan kondisi aktual di lokasi tertentu secara real-time. Penelitian ini bertujuan untuk mengklasifikasikan kondisi cuaca jalan raya berbasis citra CCTV menggunakan Vision Transformer (ViT). Dataset yang digunakan merupakan gabungan citra CCTV jalan raya dan dataset DAWN untuk mengatasi permasalahan ketidakseimbangan kelas. Dataset akhir terdiri atas dua kelas, yaitu cerah dan hujan, dengan jumlah masing-masing 325 citra. Seluruh citra melalui tahapan preprocessing berupa resizing, normalisasi, dan augmentasi data pada data latih. Model Vision Transformer base patch16-224 dengan bobot pretrained digunakan dengan skema pembekuan backbone dan pelatihan lapisan classifier selama 15 epoch. Hasil evaluasi menunjukkan model mencapai akurasi sebesar 88% dengan nilai precision, recall, dan F1-score yang seimbang pada kedua kelas. Hasil ini menunjukkan bahwa Vision Transformer efektif digunakan untuk klasifikasi kondisi cuaca jalan raya berbasis citra CCTV dan berpotensi dikembangkan sebagai sistem informasi cuaca berbasis visual yang mendekati real-time.

Kata Kunci— citra CCTV, deep learning, hujan, klasifikasi cuaca, Vision Transformer.

I. PENDAHULUAN

Kondisi cuaca memiliki peran penting dalam menentukan tingkat keselamatan dan kelancaran lalu lintas jalan raya. Hujan merupakan salah satu kondisi cuaca yang paling berpengaruh karena dapat menurunkan jarak pandang pengemudi, meningkatkan risiko permukaan jalan licin, serta memicu terjadinya kecelakaan lalu lintas [1], [2]. Oleh karena itu, informasi kondisi cuaca yang akurat dan tepat waktu menjadi kebutuhan penting dalam mendukung sistem transportasi yang aman dan efisien.

Informasi cuaca umumnya diperoleh dari stasiun meteorologi atau aplikasi prediksi cuaca berbasis wilayah. Namun, informasi tersebut sering kali bersifat umum dan kurang mampu merepresentasikan kondisi cuaca aktual

pada lokasi tertentu secara real-time, khususnya di ruas jalan raya atau persimpangan tertentu [2], [3]. Keterbatasan jumlah dan distribusi sensor meteorologi menjadi salah satu penyebab utama kurang optimalnya representasi kondisi cuaca pada tingkat lokal.

Di sisi lain, kamera Closed-Circuit Television (CCTV) telah banyak dipasang di jalan raya untuk keperluan pemantauan lalu lintas dan keamanan. Citra yang dihasilkan oleh CCTV menyimpan informasi visual lingkungan jalan raya yang berpotensi dimanfaatkan untuk mengenali kondisi cuaca secara otomatis. Sejumlah penelitian menunjukkan bahwa citra CCTV dapat digunakan untuk mendeteksi kondisi hujan dan cuaca cerah secara efektif menggunakan pendekatan pembelajaran mesin dan deep learning [1], [4], [5].

Perkembangan teknologi computer vision dan deep learning telah mendorong peningkatan kinerja sistem analisis citra digital. Pendekatan deep learning, khususnya Convolutional Neural Network (CNN), telah banyak digunakan untuk klasifikasi kondisi cuaca berbasis citra dan menunjukkan performa yang lebih baik dibandingkan metode konvensional [6], [7]. Namun, CNN memiliki keterbatasan dalam menangkap konteks global citra karena berfokus pada fitur lokal.

Vision Transformer (ViT) diperkenalkan sebagai pendekatan alternatif yang memanfaatkan mekanisme self-attention untuk memahami hubungan global antar bagian citra. Beberapa penelitian melaporkan bahwa ViT mampu memberikan performa yang kompetitif pada berbagai tugas klasifikasi citra, termasuk lingkungan jalan raya dan kondisi cuaca [8], [9], [10].

Meskipun demikian, penerapan deep learning untuk klasifikasi kondisi cuaca berbasis citra CCTV masih menghadapi tantangan utama berupa ketidakseimbangan data antar kelas kondisi cuaca. Kondisi cerah umumnya lebih dominan dibandingkan kondisi hujan, sehingga berpotensi menimbulkan bias model terhadap kelas mayoritas dan menurunkan performa deteksi kelas hujan sebagai kelas minoritas [11], [12]. Oleh karena itu, diperlukan strategi penanganan data yang tepat agar model dapat menghasilkan performa yang stabil dan adil [13].

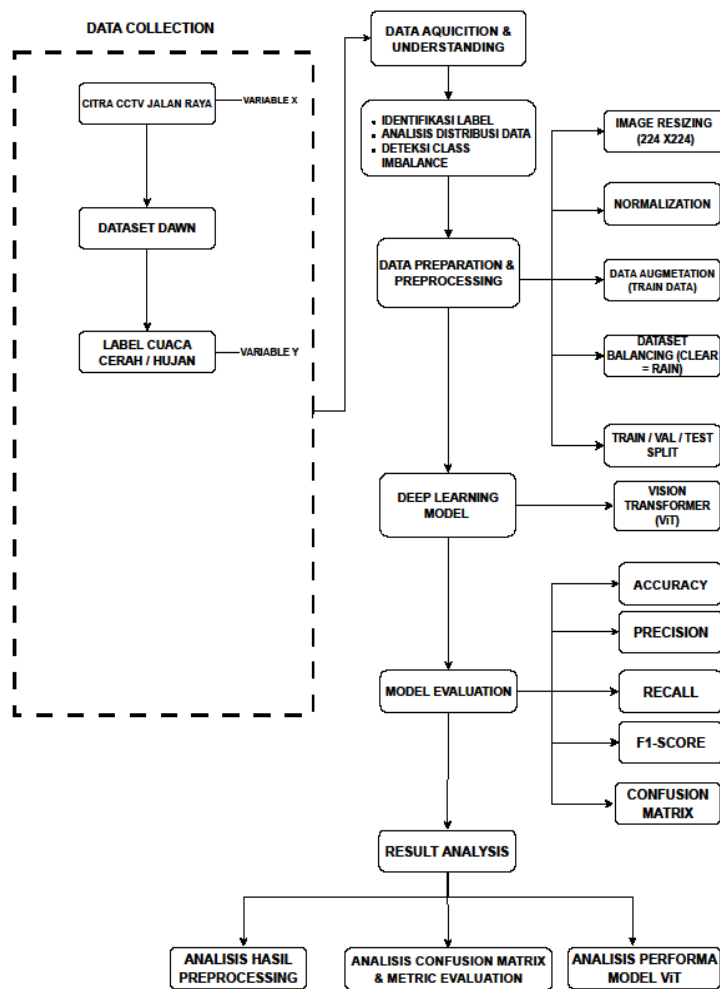
II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional untuk mengklasifikasikan kondisi cuaca dari citra CCTV jalan raya. Pendekatan kuantitatif dipilih karena kinerja model diukur secara objektif menggunakan metrik evaluasi, yaitu accuracy, precision, recall, F1-score, dan confusion matrix. Metode eksperimen komputasional diterapkan melalui proses pelatihan dan pengujian model deep learning pada dataset citra guna memperoleh performa klasifikasi kondisi cuaca cerah dan hujan.

Penelitian ini termasuk dalam jenis penelitian terapan

(applied research) karena bertujuan menghasilkan solusi praktis berupa model klasifikasi kondisi cuaca yang dapat dimanfaatkan sebagai pendukung sistem pemantauan lalu lintas dan keselamatan jalan raya berbasis citra.

Tahapan penelitian dimulai dari pengumpulan dataset citra CCTV jalan raya sebagai dataset utama dan dataset DAWN sebagai data pendukung, kemudian dilanjutkan dengan proses pemahaman data, preprocessing, pemodelan, evaluasi, dan analisis hasil. Alur metodologi penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Metodologi Penelitian

A. Tahapan Diagram Alur Penelitian

Berdasarkan Gambar 1 Diagram Alur Penelitian maka Tahapan yang dilakukan sebagai berikut:

1. Data Collection, yaitu pengumpulan data citra CCTV jalan raya sebagai dataset utama serta dataset DAWN sebagai data tambahan. Dataset DAWN digunakan untuk mengatasi ketidakseimbangan jumlah data antara kelas cerah dan hujan pada dataset awal.
2. Data Acquisition and Understanding, yaitu tahap pemahaman karakteristik dataset yang meliputi identifikasi label kondisi cuaca, analisis distribusi data, serta pendeteksian ketidakseimbangan kelas.

Hasil tahap ini digunakan sebagai dasar dalam penentuan strategi preprocessing dan penyeimbangan dataset.

3. Data Preparation and Preprocessing, yaitu tahap persiapan dataset agar sesuai dengan kebutuhan model Vision Transformer. Proses yang dilakukan meliputi perubahan ukuran citra menjadi 224×224 piksel, normalisasi nilai piksel, augmentasi data pada data latih, penyeimbangan dataset, serta pembagian data ke dalam data latih, data validasi, dan data uji dengan rasio 80:10:10.
4. Pemodelan Deep Learning, yaitu penerapan model Vision Transformer (ViT) base patch16-224 dengan bobot pretrained. Pada tahap ini backbone

model dibekukan (freeze) dan hanya lapisan classifier yang dilatih untuk mengurangi risiko overfitting pada dataset yang berukuran terbatas.

5. Evaluasi Model, yaitu pengujian model menggunakan data uji untuk mengukur kinerja klasifikasi. Metrik evaluasi yang digunakan meliputi accuracy, precision, recall, F1-score, dan confusion matrix.
6. Analisis Hasil, yaitu tahap analisis menyeluruh terhadap hasil evaluasi model yang berfokus pada performa model, pengaruh penyeimbangan dataset terhadap hasil klasifikasi, serta kesalahan prediksi pada masing-masing kelas kondisi cuaca

B. Sumber dan Jenis Data

Sumber data yang digunakan dalam penelitian ini berasal dari dua dataset utama, yaitu citra CCTV jalan raya dan dataset DAWN (Data Augmentation for Weather Nowcasting). Dataset citra CCTV jalan raya digunakan sebagai sumber data utama yang merepresentasikan kondisi visual lingkungan jalan raya dengan variasi kondisi cuaca, sedangkan dataset DAWN digunakan sebagai data tambahan untuk meningkatkan jumlah data pada kelas hujan guna mengatasi permasalahan ketidakseimbangan data (class imbalance).

Jenis data yang digunakan merupakan data citra digital dengan format JPG. Variabel independen (X) berupa citra CCTV jalan raya, sedangkan variabel dependen (Y) berupa label kondisi cuaca yang terdiri dari dua kelas, yaitu cerah (clear) dan hujan (rain).

C. Deskripsi Dataset

Dataset awal memiliki distribusi data yang tidak seimbang, dengan jumlah citra kondisi cerah sebanyak 771 citra dan kondisi hujan sebanyak 125 citra. Ketidakseimbangan ini berpotensi menyebabkan model menjadi bias terhadap kelas mayoritas dan menurunkan performa deteksi kelas minoritas. Oleh karena itu, dilakukan penambahan data hujan dari dataset DAWN dan proses penyeimbangan data sehingga diperoleh dataset akhir yang seimbang, masing-masing terdiri dari 325 citra untuk kelas cerah dan hujan dengan total 650 citra.

Dataset yang telah disiapkan selanjutnya dibagi ke dalam data latih, data validasi, dan data uji dengan rasio 80:10:10. Pembagian ini bertujuan untuk memastikan proses pelatihan dan evaluasi model dapat dilakukan secara adil dan representatif.

Untuk memberikan gambaran visual mengenai dataset yang digunakan, contoh citra untuk masing-masing kelas ditunjukkan pada Gambar 2 dan Gambar 3.



Gambar 2. Contoh Citra Dataset Clear



Gambar 3. Contoh Citra Dataset Rain

Gambar tersebut menunjukkan perbedaan karakteristik visual antara kondisi cerah (clear) dan hujan (rain), di mana kondisi hujan ditandai oleh permukaan jalan yang basah, pantulan cahaya, serta penurunan visibilitas akibat intensitas air hujan.

D. Preprocessing Data

Seluruh citra pada dataset melalui tahapan preprocessing untuk menyesuaikan kebutuhan input model Vision Transformer. Tahapan preprocessing meliputi perubahan ukuran citra menjadi 224×224 piksel, normalisasi nilai piksel, serta penerapan augmentasi data pada data latih. Augmentasi data dilakukan untuk meningkatkan kemampuan generalisasi model terhadap variasi kondisi visual citra CCTV jalan raya, seperti variasi pencahayaan dan sudut pandang kamera.

E. Pemodelan Vision Transformer

Model yang digunakan dalam penelitian ini adalah Vision Transformer (ViT) base patch16-224 dengan bobot pretrained. Pada tahap implementasi, backbone model dibekukan (freeze) dan hanya lapisan classifier yang dilatih. Strategi ini bertujuan untuk mengurangi risiko overfitting mengingat ukuran dataset yang relatif terbatas serta memanfaatkan kemampuan transfer learning dari model yang telah dipra-latih pada dataset berskala besar.

Proses pelatihan model dilakukan selama 15 epoch menggunakan optimizer AdamW dengan learning rate sebesar 2×10^{-4} . Model dengan nilai validation loss terendah disimpan sebagai model terbaik dan digunakan pada tahap evaluasi.

F. Evaluasi Model

Evaluasi performa model dilakukan menggunakan data uji yang tidak digunakan pada proses pelatihan dan validasi. Metrik evaluasi yang digunakan meliputi accuracy, precision, recall, F1-score, dan confusion matrix untuk mengukur kemampuan model dalam mengklasifikasikan kondisi cuaca secara akurat dan seimbang.

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen dan pembahasan terkait performa model Vision Transformer (ViT) dalam mengklasifikasikan kondisi cuaca dari citra CCTV jalan raya. Pengujian dilakukan untuk mengevaluasi kemampuan model dalam membedakan kondisi cerah dan hujan, serta menganalisis pengaruh penyeimbangan dataset terhadap hasil klasifikasi.

A. Tahapan penelitian

Tahap awal penelitian difokuskan pada persiapan dan preprocessing data citra CCTV jalan raya. Dataset yang digunakan merupakan gabungan antara dataset awal citra CCTV dan dataset tambahan DAWN. Penggabungan dataset ini dilakukan untuk mengatasi permasalahan ketidakseimbangan jumlah data antar kelas pada dataset awal.

Dataset awal memiliki distribusi kelas yang tidak seimbang, dengan jumlah citra kondisi cerah sebanyak

771 citra dan kondisi hujan sebanyak 125 citra. Kondisi ini berpotensi menyebabkan model cenderung bias terhadap kelas mayoritas dan menurunkan performa deteksi kelas hujan sebagai kelas minoritas. Oleh karena itu, dilakukan penambahan data kondisi hujan dari dataset DAWN serta penyesuaian jumlah data sehingga diperoleh dataset akhir yang seimbang, yaitu masing-masing 325 citra untuk kelas cerah dan hujan.

Pada tahap preprocessing, seluruh citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan kebutuhan input arsitektur Vision Transformer (ViT). Selanjutnya dilakukan normalisasi nilai piksel untuk menstabilkan proses pelatihan model. Untuk meningkatkan kemampuan generalisasi model terhadap variasi kondisi visual jalan raya, augmentasi data diterapkan pada data latih, meliputi rotasi citra, flipping horizontal, dan penyesuaian warna. Seluruh tahapan preprocessing ini dilakukan sesuai dengan implementasi pada kode penelitian

B. Implementasi Model

Dataset yang telah melalui tahap preprocessing selanjutnya dibagi menjadi tiga subset data, yaitu data latih, data validasi, dan data uji dengan rasio 80:10:10. Dari total 650 citra, pembagian dataset menghasilkan 520 citra data latih, 65 citra data validasi, dan 65 citra data uji. Setiap subset data memiliki distribusi kelas yang seimbang antara kondisi cerah dan hujan.

Model yang digunakan dalam penelitian ini adalah Vision Transformer (ViT) base patch16-224 dengan bobot pretrained. Pada tahap implementasi, backbone Vision Transformer dibekukan (freeze) dan hanya bagian classifier yang dilatih untuk mengurangi risiko overfitting mengingat ukuran dataset yang relatif terbatas.

Proses pelatihan model dilakukan selama 15 epoch menggunakan optimizer AdamW dengan learning rate sebesar 2×10^{-4} . Selama proses pelatihan, nilai training loss dan validation loss menunjukkan penurunan secara bertahap dan stabil. Model dengan nilai validation loss terendah disimpan sebagai model terbaik dan digunakan pada tahap evaluasi menggunakan data uji

Evaluasi performa model dilakukan menggunakan data uji yang tidak terlibat dalam proses pelatihan dan validasi. Evaluasi dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan kondisi cuaca cerah dan hujan secara objektif.

C. Pengujian dan Evaluasi

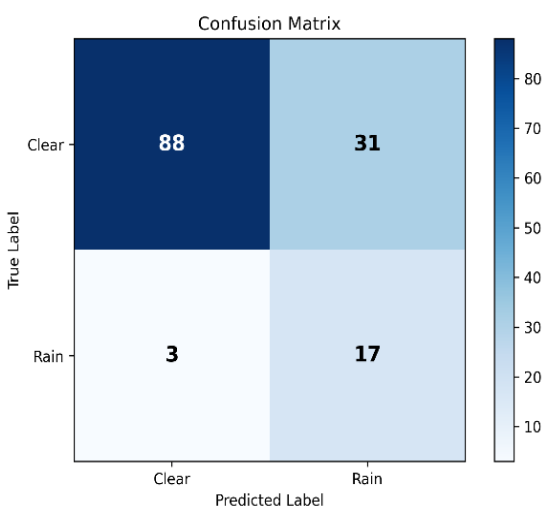
1. Evaluasi Model Menggunakan Dataset Tidak Seimbang

Dataset awal yang digunakan dalam penelitian ini memiliki distribusi kelas yang tidak seimbang, dengan jumlah citra kondisi cerah sebanyak 771 citra dan kondisi hujan sebanyak 125 citra. Ketidakseimbangan ini menyebabkan dominasi kelas cerah dan berpotensi menimbulkan bias model terhadap kelas mayoritas. Evaluasi performa model pada kondisi dataset tidak seimbang dilakukan menggunakan data uji, dan hasil pengujian tersebut disajikan pada Tabel 1.

Tabel 1. Hasil Evaluasi Model Menggunakan Dataset Tidak Seimbang

Kelas	Precision	Recall	F1-score	Support
Clear	0,97	0,74	0,84	119
Rain	0,35	0,85	0,50	20
Accuracy			0,76	139

Berdasarkan Tabel 1, hasil evaluasi pada dataset tidak seimbang menunjukkan bahwa meskipun model memiliki nilai recall yang cukup tinggi pada kelas hujan, nilai precision dan F1-score relatif rendah. Hal ini mengindikasikan bahwa model cenderung menghasilkan prediksi hujan yang keliru pada citra kondisi cerah. Temuan ini menunjukkan bahwa ketidakseimbangan dataset berdampak signifikan terhadap kestabilan dan keadilan performa model klasifikasi.



Gambar 4. Confusion Matrix Model Dataset Tidak Seimbang

Berdasarkan Gambar 4, hasil confusion matrix menunjukkan bahwa jumlah prediksi pada masing-masing kelas belum seimbang. Model cenderung menghasilkan prediksi yang lebih baik pada kelas cerah (clear) sebagai kelas mayoritas, dibandingkan kelas hujan (rain) sebagai kelas minoritas. Hal ini mengindikasikan adanya bias model terhadap kelas cerah akibat distribusi data yang tidak seimbang pada dataset awal.

Kesalahan klasifikasi yang terjadi didominasi oleh citra cerah yang diprediksi sebagai hujan, yang menunjukkan rendahnya ketepatan (precision) pada kelas hujan. Meskipun model memiliki kemampuan yang cukup baik dalam mendeteksi sebagian besar kondisi hujan (recall tinggi), jumlah prediksi hujan yang keliru pada citra cerah masih relatif tinggi. Kondisi ini disebabkan oleh keterbatasan variasi data hujan pada dataset awal serta kemiripan pola visual tertentu, seperti pantulan cahaya, bayangan jalan basah, atau pencahayaan rendah, yang menyerupai karakteristik hujan.

Secara keseluruhan, confusion matrix ini memperlihatkan bahwa ketidakseimbangan data berpengaruh signifikan terhadap performa model, khususnya dalam membedakan kelas minoritas

secara konsisten. Temuan ini menjadi dasar dilakukannya proses penyeimbangan dataset pada eksperimen selanjutnya untuk meningkatkan kestabilan dan keadilan performa klasifikasi.

2. Penyeimbang Dataset dan Penambahan Data Hujan

Untuk mengatasi permasalahan ketidakseimbangan dataset, dilakukan penambahan data citra kondisi hujan menggunakan dataset DAWN (Data Augmentation for Weather Nowcasting). Dataset DAWN dipilih karena memiliki karakteristik visual hujan yang relevan dengan lingkungan luar ruang, mirip dengan citra CCTV.

Penambahan data hujan dilakukan hingga jumlah citra pada kelas hujan setara dengan kelas cerah. Setelah proses seleksi dan penyesuaian, diperoleh dataset akhir yang seimbang dengan masing-masing 325 citra untuk kelas cerah dan hujan, sehingga total dataset berjumlah 650 citra.

Langkah penyeimbangan ini bertujuan untuk memberikan kesempatan yang sama bagi model dalam mempelajari karakteristik visual kedua kelas dan mengurangi bias terhadap kelas mayoritas.

3. Evaluasi Model Menggunakan Dataset Seimbang

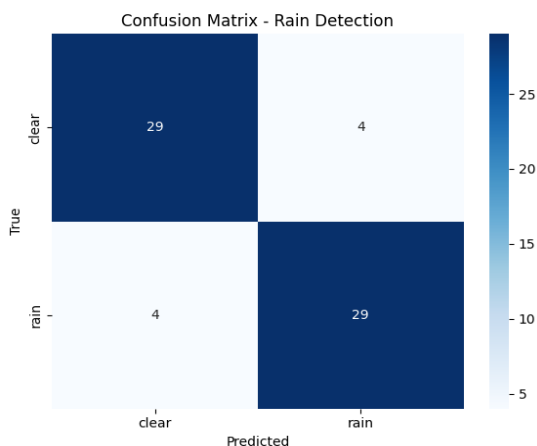
Setelah dataset diseimbangkan, dilakukan pelatihan dan evaluasi ulang model Vision Transformer. Hasil evaluasi menunjukkan peningkatan yang signifikan pada kestabilan performa model, ditunjukkan oleh nilai precision, recall, dan F1-score yang seimbang pada kedua kelas. Hasil evaluasi model Vision Transformer menggunakan dataset seimbang disajikan pada Tabel 2.

Tabel 2. Hasil Performa Model Dataset Seimbang

Kelas	Precision	Recall	F1-score	Support
Clear	0,88	0,88	0,88	33
Rain	0,88	0,88	0,88	33
Accuracy			0,88	66

Berdasarkan Tabel 2, model Vision Transformer menunjukkan performa yang seimbang pada kedua kelas, yaitu cerah dan hujan. Nilai precision, recall, dan F1-score yang sama pada kedua kelas mengindikasikan bahwa model tidak mengalami bias terhadap salah satu kelas. Nilai akurasi sebesar 88% menunjukkan bahwa model mampu melakukan klasifikasi kondisi cuaca dengan tingkat ketepatan yang baik pada data uji.

Untuk memberikan gambaran yang lebih rinci mengenai hasil prediksi model, digunakan confusion matrix yang ditunjukkan pada Gambar 3.



Gambar 5. Confusion matrix Model Dataset Seimbang

Berdasarkan Gambar 5, jumlah prediksi benar pada masing-masing kelas relatif seimbang. Hal ini menunjukkan bahwa proses penyeimbangan dataset berhasil mengurangi bias model terhadap salah satu kelas. Kesalahan klasifikasi yang terjadi sebagian besar disebabkan oleh kondisi visual yang ambigu, seperti hujan ringan atau kondisi pencahayaan rendah yang menyerupai kondisi cerah.

4. Pembahasan Performa Model

Perbedaan hasil evaluasi antara dataset seimbang dan tidak seimbang menunjukkan bahwa distribusi data memiliki pengaruh yang signifikan terhadap performa model Vision Transformer. Pada dataset seimbang, model mampu menghasilkan nilai precision, recall, dan F1-score yang konsisten pada kedua kelas tanpa perlu penerapan pembobotan kelas tambahan.

Kemampuan Vision Transformer dalam menangkap hubungan global antar bagian citra melalui mekanisme self-attention terbukti efektif dalam mengenali pola visual kondisi cuaca pada citra CCTV jalan raya yang memiliki kompleksitas visual tinggi. Dengan distribusi data yang seimbang, model dapat mempelajari karakteristik visual kedua kelas secara lebih optimal dan mengurangi kecenderungan bias terhadap kelas mayoritas

IV. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa penerapan Vision Transformer (ViT) mampu mengklasifikasikan kondisi cuaca cerah dan hujan pada citra CCTV jalan raya dengan kinerja yang baik. Model Vision Transformer base patch16-224 dengan bobot pretrained mampu mengenali pola visual kondisi cuaca secara efektif melalui mekanisme self-attention yang menangkap hubungan global antar bagian citra. Hasil pengujian memperlihatkan bahwa distribusi data yang seimbang memberikan pengaruh signifikan terhadap kestabilan dan keadilan performa model, yang ditunjukkan oleh nilai precision, recall, dan F1-score yang seimbang pada kedua kelas serta akurasi mencapai 88%.

Selain itu, tahapan preprocessing dan augmentasi data berperan penting dalam meningkatkan kemampuan generalisasi model terhadap variasi pencahayaan dan kondisi visual pada citra CCTV jalan raya. Perbandingan hasil evaluasi antara dataset tidak seimbang dan dataset seimbang menegaskan bahwa penanganan ketidakseimbangan data merupakan faktor krusial dalam klasifikasi kondisi cuaca berbasis citra, khususnya untuk meningkatkan performa deteksi kelas hujan sebagai kelas minoritas. Dengan demikian, hasil penelitian ini memiliki kontribusi penting sebagai dasar pengembangan sistem pemantauan kondisi cuaca berbasis citra CCTV yang bersifat spesifik lokasi dan mendekati real-time untuk mendukung keselamatan dan manajemen lalu lintas jalan raya.

Untuk pengembangan selanjutnya, disarankan agar penelitian menggunakan dataset yang lebih besar dan lebih beragam dari berbagai lokasi serta sudut pandang kamera CCTV guna meningkatkan kemampuan adaptasi model. Klasifikasi kondisi cuaca juga dapat diperluas ke dalam skema multi-kelas agar sistem yang dikembangkan lebih aplikatif dalam kondisi nyata. Selain itu, penelitian lanjutan dapat mengeksplorasi perbandingan dengan arsitektur deep learning lain atau penerapan fine-tuning yang lebih mendalam, serta mengintegrasikan model ke dalam sistem pemantauan berbasis streaming CCTV untuk pengujian pada kondisi operasional sebenarnya.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Dinas Komunikasi dan Informatika Kabupaten Purwakarta atas kesempatan, dukungan, dan fasilitas yang diberikan selama pelaksanaan kegiatan Internship 1 sehingga penelitian ini dapat dilaksanakan dengan baik. Penulis juga menyampaikan apresiasi kepada dosen pembimbing Program Studi D4 Teknik Informatika Universitas Logistik dan Bisnis Internasional atas bimbingan, arahan, dan masukan yang diberikan selama proses penelitian dan penyusunan artikel ini. Ucapan terima kasih turut disampaikan kepada seluruh pihak yang telah membantu dan mendukung pelaksanaan penelitian ini, baik secara langsung maupun tidak langsung.

DAFTAR PUSTAKA

- [1] A. L. Hakim and R. Dewi, "Automatic Rain Detection System Based on Digital Images of CCTV Cameras Using Convolutional Neural Network Method," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 893, no. 1, pp. 0–6, 2021, doi: 10.1088/1755-1315/893/1/012048.
- [2] X. Wang, K. Zhao, H. Huang, A. Zhou, and H. Chen, "Surveillance Camera-Based Deep Learning Framework for High-Resolution Near Surface Precipitation Type Observation," *Atmos. Meas. Tech.*, vol. 18, no. 20, pp. 5457–5484, 2025, doi: 10.5194/amt-18-5457-2025.
- [3] S. B. Sipayung, L. Slamet, E. Maryadi, I. Susanti, and A. Nurlatifah, "Evaluation of CCTV Data for Estimating Rainfall Condition," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 893, no. 1, 2021, doi: 10.1088/1755-1315/893/1/012051.
- [4] M. N. Khan and M. M. Ahmed, "Weather and surface condition detection based on road-side webcams: Application of pre-trained Convolutional Neural Network," *Int. J. Transp. Sci. Technol.*, vol. 11, no. 3, pp. 468–483, 2022, doi: 10.1016/j.ijst.2021.06.003.
- [5] K. Dahmane, P. Duthon, F. Bernardin, and M. Colomb, "Weather Classification with traffic surveillance cameras," *25th ITS World Congr.*, no. September, pp. 17–21, 2018.
- [6] S. Riyadi, D. Pardede, and R. N. Fuad, "Klasifikasi Kategori Cuaca Berdasarkan Citra Menggunakan VGG-16," *Data Sci. Indones.*, vol. 4, no. 1, pp. 91–98, 2024, doi: 10.47709/dsi.v4i1.4664.
- [7] H. Xiao, F. Zhang, Z. Shen, K. Wu, and J. Zhang, "Classification of Weather Phenomenon From Images by Using Deep Convolutional Neural Network," *Earth Sp. Sci.*, vol. 8, no. 5, pp. 1–9, 2021, doi: 10.1029/2020EA001604.
- [8] A. Abdelraouf, M. Abdel-Aty, and Y. Wu, "Using Vision Transformers for Spatial-Context-Aware Rain and Road Surface Condition Detection on Freeways," *IEEE Trans. Intell. Transp. Syst.*, vol. 23, no. 10, pp. 18546–18556, 2022, doi: 10.1109/TITS.2022.3150715.
- [9] C. Dewi, M. A. Arshed, H. J. Christanto, H. A. Rehman, A. Muneer, and S. Mumtaz, "Enhancing Weather Scene Identification Using Vision Transformer," *World Electr. Veh. J.*, vol. 15, no. 8, 2024, doi: 10.3390/wevj15080373.
- [10] A. Dosovitskiy, L. Bayer, A. Kolesnikov, "an Image Is Worth 16X16 Words: Transformers for Image Recognition At Scale," *ICLR 2021 - 9th Int. Conf. Learn. Represent.*, 2021.
- [11] D. Kumar and N. Muhammad, "through Data Merging and YOLOv8," 2023.
- [12] M. Samo, J. M. Mafeni Mase, and G. Figueredo, "Deep Learning with Attention Mechanisms for Road Weather Detection," *Sensors*, vol. 23, no. 2, 2023, doi: 10.3390/s23020798.
- [13] H. Gupta, O. Kotlyar, H. Andreasson, and A. J. Lilienthal, "Video WeAtHer RecoGnition (VARG): An Intensity-Labeled Video Weather Recognition Dataset," *J. Imaging*, vol. 10, no. 11, pp. 1–16, 2024, doi: 10.3390/jimaging10110281.