

Klasifikasi Cuaca Berbasis Citra Menggunakan ConvNeXt

Bagus Ajie Satria^{a1}, Ida Ayu Gde Suwiprabayanti Putra^{a2}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana
Jalan Raya Kampus UNUD, Bukit Jimbaran, Kuta Selatan, Badung, Bali, Indonesia
¹satria.2308561044@student.unud.ac.id
²iagsuwiprabayantiputra@unud.ac.id

Abstract

Weather image classification plays a crucial role in many sectors, such as transportation, marine, and agriculture, where automated weather recognition can support decision-making and safety. This study proposes the use of the ConvNeXt architecture with transfer learning for weather classification using image data. The dataset, sourced from Kaggle, comprises 768 images labeled into three categories: cloudy, rain, and shine. Several preprocessing steps were conducted, including noise filtering, resizing, normalization, and augmentation to enhance model performance. Furthermore, a hyperparameter tuning process was applied using six different combinations of learning rates and batch sizes to identify the most optimal configuration. The ConvNeXt model achieved perfect evaluation scores of 100% on validation sets for two hyperparameter combinations and testing sets for a hyperparameter combinations, outperforming models from previous studies such as InceptionV3 and DenseNet169. The evaluation metrics used were accuracy, precision, recall, F1-score, and confusion matrix. The results demonstrate the model's robustness and effectiveness in classifying weather conditions based on image data. This study shows that ConvNeXt is a highly capable architecture for visual weather classification tasks.

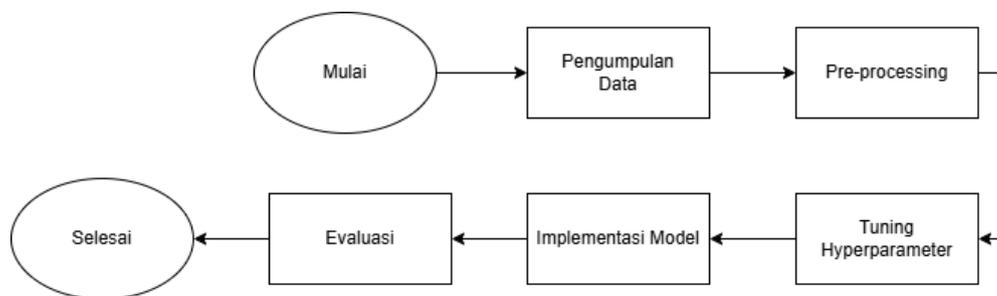
Keywords: ConvNeXt, Weather Classification, Deep Learning, Tuning Hyperparameter

1. Pendahuluan

Citra cuaca memiliki peran yang cukup penting di beberapa bidang dalam kehidupan manusia seperti pada bidang penerbangan, kelautan, dan pertanian [1]. Perkembangan teknologi dalam bidang visi komputer (computer vision) telah memungkinkan berbagai sistem cerdas untuk mendeteksi serta mengklasifikasi suatu fenomena secara otomatis melalui pemrosesan citra [2]. Dalam kasus ini, deteksi fenomena cuaca memainkan peran penting dalam berbagai aplikasi, seperti prakiraan cuaca, pemantauan jalan, dan transportasi [3]. Integrasi teknik visi komputer untuk mengotomatiskan deteksi cuaca secara *real-time* membuat penelitian ini lebih relevan untuk dilaksanakan. Kontribusi yang dibawakan pada penelitian ini adalah potensinya untuk meningkatkan ketepatan dan efektivitas model dalam mengklasifikasi cuaca, terutama ketika menggunakan teknik pemodelan canggih yang memanfaatkan citra sebagai data inputnya. Terdapat beberapa penelitian terdahulu yang telah membahas mengenai klasifikasi cuaca berbasis citra menggunakan berbagai metode *deep learning* yang berbeda. Penelitian yang berjudul "Klasifikasi Citra Cuaca Menggunakan Inception-V3 dan K-Nearest Neighbors" menggunakan 1748 citra cuaca sebagai dataset dengan 4 kategori untuk melakukan pelatihan yang menghasilkan model dengan Accuracy 91%, F1 91%, Recall 91%, Precision 91% [1]. Penelitian selanjutnya yang berjudul "Comparative Analysis of Weather Image Classification Using CNN Algorithm with InceptionV3, DenseNet169 and NASNetMobile Architecture Models" mendapat hasil terbaik pada model InceptionV3 dengan akurasi sebesar 97.94% dengan data pelatihan, 93.81% dengan data validasi, dan 93.81% dengan data uji. Sementara pada model DenseNet169 dicapai akurasi sebesar 98,09% pada data pelatihan, 88,46% pada data validasi, dan 92,33% pada data uji. Model NASNetMobile mencapai akurasi 96,51% pada data pelatihan, 87,82% pada data validasi, dan 89,97% pada data uji [4]. Pada penelitian yang berjudul "A Study

of Weather-Image Classification Combining VIT and a Dual Enhanced-Attention Module” menggunakan gabungan dari model Vision Transformers (VIT) dengan Dual Enhanced-Attention Module yang digunakan untuk memperoleh representasi semantik citra dalam tingkat rendah dan tingkat tinggi, serta vektor fitur disambung dan dimasukkan ke dalam lapisan linier untuk memperoleh jenis cuaca. Hasil penelitian menunjukkan bahwa model tersebut memperoleh skor F1 tertinggi yaitu 97,47%, 87,69% dan 92,73% pada dataset Multi-Weather Dataset (MWD), Weather Phenomenon Database (WEAPD) dan gabungan kedua dataset tersebut, serta didapat akurasi sebesar 97,48% dengan dataset MWD [5]. Penelitian akan menggunakan model ConvNeXt serta menerapkan *transfer learning* dengan menggunakan bobot awal dari ImageNet, dan di-fine-tune untuk mengklasifikasikan kategori cuaca berbasis citra. Model ConvNeXt digunakan karena model ini dapat bersaing secara menguntungkan dengan model Transformers dalam hal akurasi dan skalabilitas, mencapai akurasi ImageNet top-1 sebesar 87,8% dan mengungguli Swin Transformers dalam deteksi COCO dan segmentasi ADE20K [6]. Alasan penggunaan model ini juga didukung dengan penelitian yang berjudul “Application of ConvNeXt with transfer learning and data augmentation for malaria parasite detection in resource-limited settings using microscopic images” dimana model ConvNeXt Tiny V2 mendapat akurasi sebesar 98.1% dari total 606276 gambar dataset darah tipis dalam mendeteksi penyakit malaria [7].

2. Metode Penelitian



Gambar 1. Diagram Alur Penelitian

Penelitian ini mengimplementasikan model ConvNeXt dalam klasifikasi cuaca berbasis citra. *Output* yang akan dihasilkan pada penelitian ini adalah hasil evaluasi dari pengujian model ConvNeXt dengan dataset yang didapat. Dapat dilihat pada gambar 1, alur penelitian yang dilakukan terdiri dari 5 proses, dimulai dari proses pengumpulan data, melakukan pre-processing, *hyperparameter tuning*, mengimplementasikan proses klasifikasi menggunakan ConvNeXt, dan melakukan evaluasi dengan mengukur metrik evaluasi serta confusion matrix.

2.1 Pengumpulan Data

Dataset yang digunakan pada penelitian ini adalah dataset citra cuaca sesuai dengan labelnya. Dataset dikumpulkan dari sumber sekunder yang didapat dari platform kaggle [8]. Jumlah keseluruhan dataset berjumlah 768 file dengan 3 label, yaitu *cloudy* (300 gambar), *rain* (215 gambar), *shine* (253 gambar). Contoh file pada dataset berdasarkan label dapat dilihat pada gambar 2.



Gambar 2. File Sampel Dataset Sesuai Label

2.2 Pre-processing

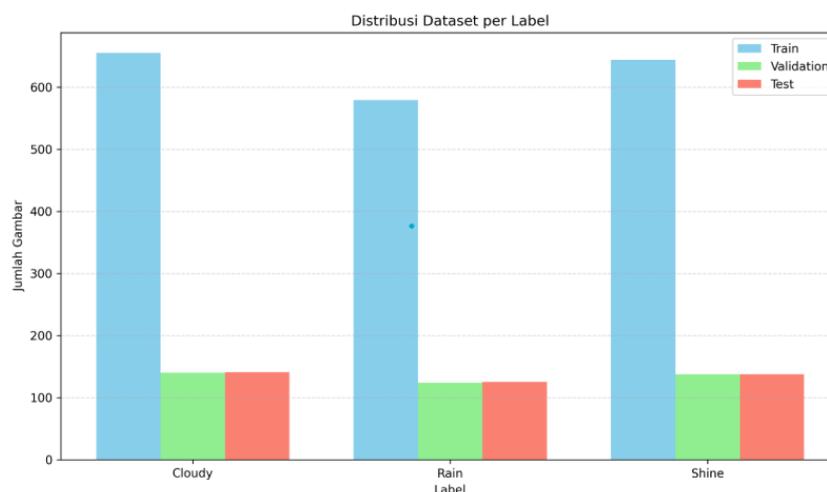
Pre-processing merupakan tahapan pembersihan dan penyesuaian data sebelum data digunakan untuk melatih model *deep learning* [9]. Pada penelitian ini, pre-processing data meliputi:

- **Data filtering** adalah proses menghapus atau mengoreksi citra yang memiliki noise berat, blur, atau distorsi yang dapat mengganggu proses ekstraksi fitur oleh model. Data filtering berguna untuk Menjaga kualitas input agar model dapat belajar dari citra yang relevan dan jelas.
- **Image resize** yaitu mengubah semua ukuran gambar pada dataset menjadi suatu ukuran yang telah ditentukan, dalam kasus ini yaitu 224×224 px. Menyamaratakan ukuran citra dengan ukuran input arsitektur model serta berguna untuk menjaga konsistensi data dan mengurangi kompleksitas komputasi.
- **Normalisasi pixel** yaitu merubah rentang piksel dari rentang 0-255 menjadi 0-1. Proses normalisasi Membantu konvergensi lebih cepat selama pelatihan serta menstabilkan nilai input agar tidak terlalu besar/kecil.
- **Augmentasi** merupakan proses untuk menambah jumlah dataset serta meningkatkan keragaman dataset dengan membuat data baru secara artifisial dari data yang sudah ada. Proses augmentasi yang dilakukan yaitu berupa *horizontal flip* merupakan proses pembalikan citra secara horizontal, translasi merupakan pengaturan cahaya dan kontras pada citra, *scaling/cropping* yaitu mengatur ukuran gambar baik dengan memotong ataupun mengatur skalanya, dan rotasi yaitu mengatur rotasi citra sesuai dengan sudut derajat yang ditentukan. Persebaran jumlah file sebelum dan sesudah di augmentasi dapat dilihat pada tabel 1.

Tabel 1. Jumlah Keseluruhan Dataset Sebelum dan Setelah Augmentasi

Keterangan	Jumlah
Pra Augmentasi	768
Pasca Augmentasi	2684

- **Data Split** merupakan proses pembagian dataset untuk proses pelatihan, validasi, dan pengujian. Persentase pembagian dataset yang dilakukan pada penelitian ini adalah 70% untuk data latih, 15% untuk data validasi, serta 15% untuk data uji. Pembagian ini dilakukan agar model tidak mengalami *overfitting* saat menjalankan testing, serta data validasi diperlukan untuk melakukan validasi pada hasil dari setiap *tuning hyperparameter*.



Gambar 3. Grafik Distribusi Dataset per Label

Gambar 3 menunjukkan distribusi pembagian dataset pada masing-masing label. Pada label *Cloudy* total data latih berjumlah 655 gambar, total data validasi berjumlah 140, dan total data uji berjumlah 141. Pada label *Rain* total data latih berjumlah 579 gambar, total data validasi berjumlah 124, dan total data uji berjumlah 125. Pada label *Shine* total data latih berjumlah 644 gambar, total data validasi berjumlah 138, dan total data uji berjumlah 138.

2.3 Tuning Hyperparameter

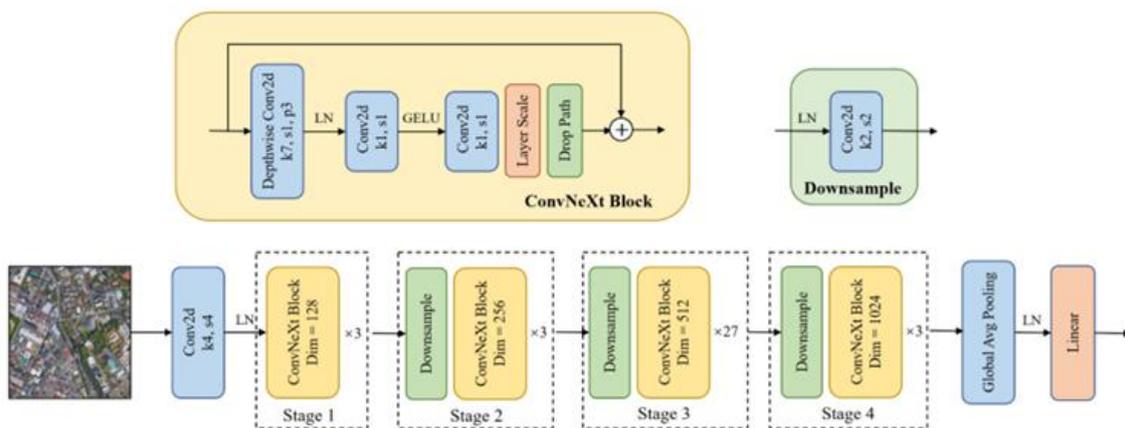
Hyperparameter tuning memiliki peran yang sangat penting dalam mengoptimalkan kinerja algoritma machine learning (ML) apa pun. Nilai dari hyperparameter tidak dapat ditentukan dari data dan selalu kita ambil saat pendefinisian model dengan kata lain nilai hyperparameter harus ditetapkan sebelum sebuah model menjalani proses pembelajarannya. Hyperparameter merupakan variabel yang memengaruhi output dari sebuah model [10]. Hyperparameter yang akan ditentukan pada penelitian ini, yaitu *learning rate* dan *batch size*. Kode model berfungsi untuk mewakili satu kombinasi hyperparameter. Kombinasi hyperparameter dapat dilihat pada tabel 2.

Tabel 2. Kombinasi Hyperparameter

Kode Model	Learning Rate	Batch Size
A	0.001	16
B	0.001	32
C	0.0005	16
D	0.0005	32
E	0.0001	16
F	0.0001	32

2.4 Implementasi Model

Penelitian menggunakan model ConvNeXt dalam melakukan klasifikasi cuaca berbasis citra. Model ConvNext merupakan model pre-trained yang telah di latih dengan dataset dari Image-Net yang kemudian dilakukan tuning menggunakan dataset saat ini.



Gambar 4. Arsitektur ConvNeXt [11]

Arsitektur ConvNeXt yang terlihat pada gambar 4 terdiri dari Conv2d, 4 stage, global average pooling, dan linear. Stage1 terdiri dari ConvNeXt Block sedangkan stage 2 sampai 4 terdiri dari Downsample dan ConvNeXt Block. ConvNeXt Block terdiri dari Depthwise Conv2d, 2 Conv2d, Layer Scale dan DropPath. Di sisi lain, Downsample terdiri dari Conv2d [12]. Dengan arsitektur

tersebut model dapat memperoleh representasi fitur spasial yang mendalam dan efisien, sehingga mampu mengenali pola visual kompleks seperti kondisi cuaca (cerah, hujan, berawan) secara akurat dan stabil.

2.5 Evaluasi

Metode evaluasi yang digunakan pada penelitian ini adalah metrik evaluasi yang terdiri dari *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Support* serta digunakan *Confusion Matrix*. Proses evaluasi akan diimplementasikan setelah model berhasil melalui masing-masing proses validasi serta *testing*.

a. Metrik Evaluasi

Metrik evaluasi digunakan untuk menganalisis performa model secara kuantitatif. Metrik terdiri dari *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Berikut merupakan persamaan dari setiap metrik yang di evaluasi (1) – (4).

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

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

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

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

b. Confusion Matrix

Confusion matrix adalah sebuah tabel yang digunakan untuk mengevaluasi kinerja algoritma klasifikasi dengan cara membandingkan antara label aktual dan label hasil prediksi model. Tabel ini menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas dalam klasifikasi multi-kelas. *Confusion matrix* terdiri atas empat komponen utama dalam kasus biner: True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN) [13]. Contoh tabel *Confusion Matrix* dapat dilihat pada gambar 5.

	ACTUAL	
PREDICTED	TRUE	FALSE
TRUE	TP (True Positive)	FP (False Positive)
FALSE	TN (True Negative)	FN (False Negative)

Gambar 5. Contoh Tabel *Confusion Matrix* [14]

3. Hasil dan Pembahasan

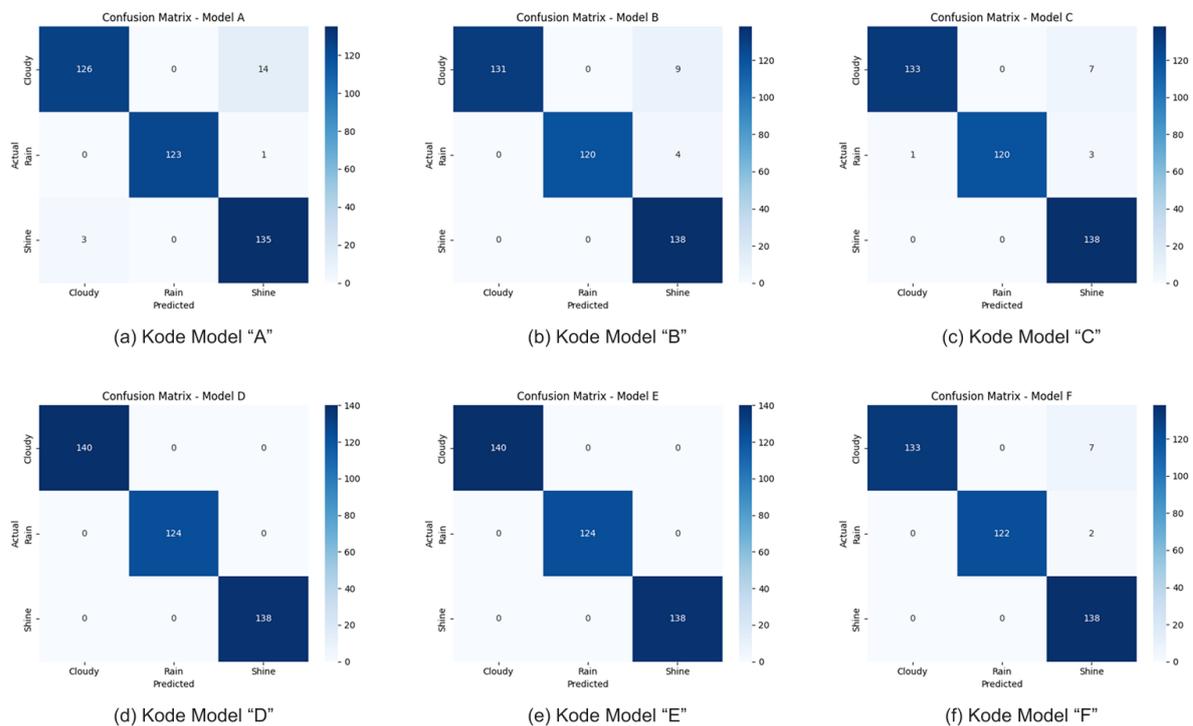
Bagian ini menyajikan hasil dari proses validasi dan testing model klasifikasi cuaca menggunakan arsitektur ConvNeXt. Pembahasan dilakukan untuk menganalisis performa model berdasarkan metrik evaluasi serta memahami efektivitas pendekatan yang digunakan dalam mengklasifikasikan citra cuaca menjadi tiga kategori: cerah, hujan, dan berawan. Setelah hasil evaluasi didapat, model akan dikomparasikan dengan model-model yang telah digunakan pada penelitian-penelitian sebelumnya.

3.1 Hasil Validasi

Setelah dilakukan *tuning hyperparameter* dan proses pelatihan, model akan lanjut ke tahap validasi dengan dataset validasi yang telah di split sebelumnya. Hasil evaluasi dari setiap kombinasi parameter ditunjukkan pada tabel 3.

Tabel 3. Hasil Metrik Evaluasi Proses Validasi Setiap Kombinasi Hyperparameter

Kode Model	Precision	Recall	F1-Score	Accuracy
A	95.89%	95.67%	95.68%	95.52%
B	97.13%	96.78%	96.85%	96.77%
C	97.5%	97.26%	97.31%	97.26%
D	100%	100%	100%	100%
E	100%	100%	100%	100%
F	97.96%	97.80%	97.82%	97.76%



Gambar 6. Confusion Matrix Validasi Setiap Kombinasi Hyperparameter

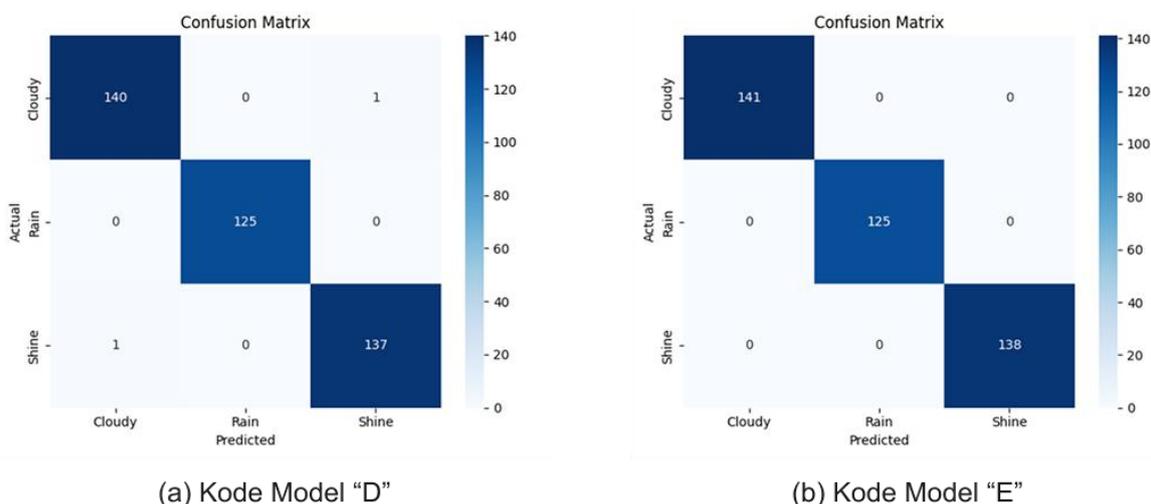
Seperti yang ditunjukkan pada tabel 3, kombinasi hyperparameter dengan kode model "D" dan "E" mendapatkan hasil yang sempurna pada metrik evaluasi. Ini menunjukkan bahwa kedua model tersebut berhasil mengklasifikasi seluruh dataset pada data validasi yang telah di split sebelumnya tanpa adanya kesalahan. Kedua model tersebut akan lanjut ke tahap testing untuk diuji performanya dengan data yang lebih baru.

3.2 Hasil Testing

Tahap testing dilakukan pada model dengan hasil terbaik pada tahap validasi untuk diuji performanya dengan data yang baru. Dalam kasus ini, proses testing akan dilakukan pada model "D" dan "E" karena kedua model tersebut berhasil mencapai hasil evaluasi terbaik pada tahap validasi. Hasil metrik evaluasi dan confusion matrix dari kedua model tersebut ditunjukkan pada tabel 4 dan gambar 7.

Tabel 4. Hasil Metrik Evaluasi Model “D” dan “E”

Kode Model	Precision	Recall	F1-Score	Accuracy
D	99.52%	99.52%	99.52%	99.5%
E	100%	100%	100%	100%



Gambar 7. Confusion Matrix Testing Model “D” dan “E”

Seperti yang ditunjukkan pada tabel 4 dan gambar 7, model “E” mendapat hasil yang lebih baik dari model “D”. Pada confusion matrix model “D” terdapat 2 kesalahan pada label prediksi *Shine* yang dimana sebenarnya merupakan label *Cloudy* dan sebaliknya. Sedangkan pada confusion matrix model “E” tidak terdapat kesalahan pada hasil prediksi model tersebut. Ini menunjukkan bahwa model arsitektur ConvNeXt dengan hyperparameter *learning rate* 0.0001 dan *batch size* 16 dapat memberikan hasil yang sangat baik dibandingkan dengan kombinasi hyperparameter lainnya.

3.3 Komparasi

Hasil dari model ConvNeXt yang telah di tuning akan di komparasikan dengan arsitektur model dari penelitian-penelitian sebelumnya dalam lingkup topik klasifikasi cuaca berbasis citra. Hasil yang di komparasi kan pada penelitian ini adalah metrik akurasi pada tahap validasi dan testing yang bertujuan untuk membandingkan performa akurasi pengklasifikasian tiap model.

Tabel 5. Perbandingan akurasi model yang diajukan dengan model dari penelitian terdahulu

Model	Validation Accuracy	Testing Accuracy
InceptionV3 [4]	92.34%	93.81%
DenseNet169 [4]	88.46%	92.33%
NASNetMobile [4]	87.82%	89.97%
VIT-DA (MWD Dataset) [5]	-	97.48%
ConvNeXt (model yang diajukan)	100%	100%

Seperti yang ditunjukkan pada tabel 5, bahwa model yang diajukan pada penelitian ini yaitu ConvNeXt yang telah dilakukan hyperparameter tuning mendapat hasil terbaik dibandingkan model-model yang digunakan pada penelitian sebelumnya. Namun, perbandingan ini belum bisa

dijadikan sebagai acuan penuh jika ingin mengkomparasikan model secara keseluruhan karena terdapat perbedaan dari jumlah file dataset serta label yang digunakan.

4. Kesimpulan

Penelitian ini berhasil mengimplementasikan model ConvNeXt dalam klasifikasi citra cuaca dengan tiga kategori yaitu cerah, hujan, dan berawan. Hasil dari proses pelatihan dan validasi menunjukkan bahwa ConvNeXt mampu mengklasifikasikan citra dengan sangat baik, khususnya pada kombinasi hyperparameter dengan kode model "E" yang memperoleh hasil evaluasi sempurna (100%) pada tahap validasi maupun testing. Hasil ini mengungguli beberapa arsitektur model deep learning lain yang telah digunakan dalam penelitian sebelumnya. Hal ini membuktikan bahwa ConvNeXt merupakan arsitektur yang efektif dan efisien dalam menangani tugas klasifikasi citra cuaca. Untuk lebih mendalami analisis model yang lebih baik, penelitian selanjutnya diharapkan dapat meningkatkan ukuran jumlah dataset serta label yang lebih variatif untuk mendapat hasil komparasi model yang lebih representatif.

Daftar Pustaka

- [1] I. G. Ritonga, R. Rosnelly, P. D. Manalu, T. Tamba, and K. Wau, "Klasifikasi Citra Cuaca Menggunakan Inception-V3 dan K-Nearest Neighbors," *Jurnal Teknologi Dan Ilmu Komputer Prima (JUTIKOMP)*, vol. 6, no. 2, pp. 118–122, Oct. 2023, doi: 10.34012/jutikomp.v6i2.4052.
- [2] J. B. Mohapatra, N. K. Nishchal, and J. Monikantan, "Object Recognition in Foggy and Hazy Conditions Using Dark Channel Prior-Based Fringe-Adjusted Joint Transform Correlator," *Photonics*, vol. 11, no. 12, Dec. 2024, doi: 10.3390/photonics11121142.
- [3] S. Riyadi, D. Pardede, and R. N. Fuad, "Klasifikasi Kategori Cuaca Berdasarkan Citra Menggunakan VGG-16," *Data Sciences Indonesia (DSI)*, vol. 4, no. 1, pp. 91–98, Sep. 2024, doi: 10.47709/dsi.v4i1.4664.
- [4] V. Wulandari, W. J. Sari, Z. H. Al-Sawaff, and S. Manickam, "Comparative Analysis of Weather Image Classification Using CNN Algorithm with InceptionV3, DenseNet169 and NASNetMobile Architecture Models," vol. 2, no. 2, pp. 81–92, 2025, doi: 10.57152/predatecs.v2i2.1609.
- [5] J. Li and X. Luo, "A Study of Weather-Image Classification Combining VIT and a Dual Enhanced-Attention Module," *Electronics (Switzerland)*, vol. 12, no. 5, Mar. 2023, doi: 10.3390/electronics12051213.
- [6] Z. Liu, H. Mao, C.-Y. Wu, C. Feichtenhofer, T. Darrell, and S. Xie, "A ConvNet for the 2020s," in *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2022, pp. 11966–11976. doi: 10.1109/CVPR52688.2022.01167.
- [7] O. P. Mmileng, A. Whata, M. Olusanya, and S. Mhlongo, "Application of ConvNeXt with transfer learning and data augmentation for malaria parasite detection in resource-limited settings using microscopic images," *PLoS One*, vol. 20, no. 6 June, Jun. 2025, doi: 10.1371/journal.pone.0313734.
- [8] Prateek Srivastava, "Multi-class Weather Dataset," Kaggle. Accessed: Jul. 02, 2025. [Online]. Available: <https://www.kaggle.com/datasets/pratik2901/multiclass-weather-dataset>
- [9] M. Faiz, T. Ahmad, and G. Mustafa, "The Nucleus Object Detection in Foggy Weather using Deep Learning Model," 2024. [Online]. Available: www.thenucleuspak.org.pk
- [10] W. Nugraha and A. Sasongko, "SISTEMASI: Jurnal Sistem Informasi Hyperparameter Tuning pada Algoritma Klasifikasi dengan Grid Search Hyperparameter Tuning on Classification Algorithm with Grid Search." [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [11] S. Chen, Y. Ogawa, C. Zhao, and Y. Sekimoto, "Large-scale individual building extraction from open-source satellite imagery via super-resolution-based instance segmentation approach," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 195, pp. 129–152, Jan. 2023, doi: 10.1016/j.isprsjprs.2022.11.006.

- [12] Y. S. Austin *et al.*, "Klasifikasi Penyakit Alzheimer Dari Scan Mri Otak Menggunakan Convnext," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 6, pp. 1223–1232, Dec. 2024, doi: 10.25126/jtiik.2024118117.
- [13] A. Tharwat, "Classification assessment methods," *Applied Computing and Informatics*, vol. 17, no. 1, pp. 168–192, 2018, doi: 10.1016/j.aci.2018.08.003.
- [14] P. Romadloni, B. Adhi Kusuma, and W. Maulana Baihaqi, "Komparasi Metode Pembelajaran Mesin Untuk Implementasi Pengambilan Keputusan Dalam Menentukan Promosi Jabatan Karyawan," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 6, no. 2, pp. 622–628, Sep. 2022, doi: 10.36040/jati.v6i2.5238.

Halaman ini sengaja dibiarkan kosong