

KLASIFIKASI KONDISI KEBERSIHAN SUNGAI DARI CITRA DIGITAL MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* DENGAN ALGORITMA *INCEPTION V3* DAN *XCEPTION*

Dika Prasetya, Bryan Hanggara, Rihan Naufaldihanif, Adley Clark Peter Wijaya, Fathoni, Ali Ibrahim

Sistem Informasi, Universitas Sriwijaya

Jl. Raya Palembang - Prabumulih No.KM. 32, Indralaya Indah, Kec. Indralaya,

Kabupaten Ogan Ilir, Sumatera Selatan

dprasetya060@gmail.com

ABSTRAK

Peningkatan pencemaran sungai menjadi isu lingkungan yang semakin mendesak untuk ditangani melalui metode pemantauan yang efisien. Namun, pemantauan manual terhadap kualitas sungai masih memiliki keterbatasan dari segi waktu dan sumber daya. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kondisi sungai menggunakan citra visual dengan pendekatan *deep learning* berbasis *transfer learning*. Dua arsitektur *Convolutional Neural Network* (CNN), yaitu Xception dan InceptionV3, digunakan sebagai model utama dengan teknik *fine-tuning* agar dapat membedakan antara sungai bersih dan sungai tercemar. *Dataset* citra diperoleh melalui metode *web scraping* dari berbagai sumber daring, kemudian diproses melalui tahapan *resize*, *augmentasi*, dan *normalisasi*. Hasil eksperimen menunjukkan bahwa kedua model mencapai akurasi pengujian sebesar 85%. Model Xception memiliki keunggulan dalam *precision* sebesar 90% dan *F1-score* 86% pada kelas sungai tercemar, meskipun menghasilkan beberapa *false negative*. Sementara itu, model InceptionV3 menunjukkan performa yang lebih seimbang dengan nilai *precision*, *recall*, dan *F1-score* sebesar 0,86. Temuan ini menunjukkan bahwa kedua model mampu mengklasifikasikan kondisi sungai secara cukup akurat dan dapat menjadi solusi alternatif dalam pemantauan kualitas lingkungan perairan secara otomatis.

Kata kunci : Klasifikasi, Kebersihan Sungai, *Convolutional Neural Network*, *Transfer Learning*, Xception, InceptionV3

1. PENDAHULUAN

Sungai merupakan salah satu sumber daya air yang sangat penting bagi keberlangsungan hidup manusia dan ekosistem sekitarnya. Namun, kualitas air sungai di Indonesia saat ini menunjukkan kondisi yang memprihatinkan. Berdasarkan studi literatur, pada tahun 2019 terdapat 98 sungai yang tersebar di Indonesia, dengan rincian 38 sungai berada dalam kategori tercemar berat, meningkat dari 25 sungai pada tahun sebelumnya [1]. Hal ini menunjukkan bahwa pencemaran sungai merupakan isu lingkungan yang mendesak dan perlu segera ditangani.

Pencemaran sungai sebagian besar disebabkan oleh limbah domestik, industri, pertanian, dan aktivitas masyarakat di sekitar sungai [2]. Sampah anorganik, seperti plastik, logam, dan kaca, merupakan kontributor signifikan terhadap penurunan kualitas air dan kerusakan ekosistem sungai [3]. Oleh karena itu, diperlukan metode yang efektif untuk memantau dan mengklasifikasikan kondisi kebersihan sungai agar langkah mitigasi dapat dilakukan secara tepat waktu.

Pengamatan visual terhadap jumlah sampah di sungai merupakan salah satu pendekatan yang umum dilakukan, mengingat sampah sering kali dapat dikenali secara kasat mata berdasarkan bentuk dan warnanya. Visualisasi ini memungkinkan untuk dimanfaatkan dalam sistem berbasis komputer menggunakan teknologi pengolahan citra digital [4]. Salah satu metode unggulan dalam pengolahan citra digital saat ini adalah *Convolutional Neural Network* yang merupakan metode *machine learning* yang memiliki fungsi untuk mengidentifikasi serta

mengenali suatu objek pada citra digital. CNN bekerja dengan operasi konvolusi yang efektif dalam mengekstraksi fitur visual dari gambar, sehingga sangat cocok untuk pengolahan data dua dimensi seperti citra. [5].

Berbagai arsitektur CNN telah diterapkan dalam penelitian klasifikasi citra, termasuk dalam domain pengelolaan sampah dan pencemaran air. Penelitian yang dilakukan oleh Christin et al. (2024) membandingkan performa model CNN ResNet18 dan ResNet50 dalam mengklasifikasikan citra sampah, yang menunjukkan tingkat akurasi hingga lebih dari 99% [3]. Sementara itu, Setyawan dan Kristian (2020) memanfaatkan CNN untuk mendeteksi sampah di sungai dan mengklasifikasikan tingkat kebersihan menjadi empat kelas berdasarkan prosentase objek sampah yang terdeteksi dalam citra video sungai [4].

Dalam penelitian ini, kami mengusulkan penggunaan algoritma Xception, yang merupakan salah satu arsitektur CNN dengan pendekatan *transfer learning*, untuk meningkatkan akurasi dalam klasifikasi kondisi kebersihan sungai. Xception dikenal memiliki performa unggul dalam ekstraksi fitur dari citra karena menggunakan *depthwise separable convolution*, yang terbukti efektif dalam berbagai tugas klasifikasi gambar. Dalam studi sebelumnya, arsitektur ini mampu mencapai akurasi hingga 85,1% dalam pengenalan bentuk wajah manusia, menunjukkan bahwa model ini cukup andal untuk diterapkan pada konteks klasifikasi visual lainnya seperti kondisi lingkungan [6]. Penelitian ini

bertujuan untuk mengembangkan model klasifikasi yang dapat memantau kondisi kebersihan sungai secara *real-time*, sehingga dapat menjadi alat bantu bagi pemerintah dan masyarakat dalam upaya pengelolaan sungai yang lebih efektif.

2. TINJAUAN PUSTAKA

ResNet50 memiliki akurasi lebih tinggi (99,41%) dibandingkan dengan ResNet18 (98,69%), namun ResNet18 memiliki waktu pelatihan yang lebih singkat, menjadikannya lebih efisien secara komputasi [3]. Penggunaan *Convolutional Neural Network* (CNN) telah terbukti efektif dalam mendeteksi objek berbasis citra digital, termasuk dalam klasifikasi tingkat kebersihan sungai berdasarkan jumlah sampah yang mengalir di permukaan air. Dengan membandingkan jumlah piksel sampah terhadap total piksel ROI, sistem dapat menghasilkan tingkat akurasi yang cukup tinggi dalam menentukan kebersihan sungai [3].

Model deteksi sampah di permukaan Sungai Ciliwung menggunakan *Convolutional Neural Network* (CNN) dengan algoritma YOLOv8 dipilih karena kecepatan dan akurasi yang tinggi dalam mendeteksi sampah yang mengapung. Hasil terbaik dicapai pada epoch ke-177 dengan Precision sebesar 84,02%, Recall sebesar 91,03%, dan F1-Score sebesar 87,38% [7].

CNN telah berkembang menjadi salah satu metode paling populer dalam klasifikasi berbasis citra. Model klasifikasi penyakit daun lemon dengan arsitektur transfer learning seperti DenseNet-201, ResNet-50, ResNet-15V2, dan *Xception* menunjukkan bahwa model *Xception* memiliki performa terbaik dengan akurasi 94,34%, mengungguli model lainnya. Sistem otomatis ini memungkinkan petani dan masyarakat umum mengenali penyakit daun lemon hanya dengan mengambil gambar, sehingga dapat melakukan tindakan preventif lebih awal [8]. CNN juga diterapkan dalam bidang kesehatan, seperti klasifikasi penyakit paru-paru berbasis citra X-ray. Model yang dibandingkan antara lain SqueezeNet, VGG11, ResNet18, DenseNet, dan MobileNetV2, di mana MobileNetV2 memberikan akurasi terbaik (88,5%). Model ini dikembangkan lebih lanjut dengan teknik *fine-tuning* dan mekanisme *attention*, yang meningkatkan akurasi menjadi 93,3%. Studi ini membuktikan bahwa CNN dapat digunakan untuk mendukung keputusan medis dalam mendiagnosa penyakit paru-paru lebih cepat dan akurat [9].

Selain dalam klasifikasi penyakit tanaman dan kesehatan, CNN juga diterapkan dalam penilaian kualitas produk pertanian. Model CNN dengan arsitektur AlexNet berhasil mencapai akurasi 99,8% dalam membedakan buah segar dan busuk melalui preprocessing gambar, augmentasi data, serta fine-tuning model CNN. Pendekatan ini memungkinkan industri pertanian dan ritel meningkatkan efisiensi dalam pemilihan buah [10].

Transfer learning memungkinkan model memanfaatkan fitur yang telah dipelajari dari dataset

lain, sehingga meningkatkan akurasi dengan waktu pelatihan yang lebih efisien, terutama dalam kasus dataset yang terbatas. Dalam penelitian ini, *transfer learning* digunakan untuk mengembangkan sistem klasifikasi tingkatan pencemaran sungai berdasarkan citra digital, yang mencakup kondisi seperti sungai bersih, tercemar ringan, dan tercemar berat. Berbeda dengan penelitian sebelumnya yang cenderung bersifat umum, penelitian ini bertujuan untuk mengidentifikasi dan mengklasifikasikan tingkat pencemaran yang terjadi secara lebih spesifik, sehingga dapat memberikan informasi yang lebih akurat untuk pengelolaan kualitas air sungai. Dengan pendekatan ini, sistem yang dikembangkan diharapkan mampu meningkatkan efektivitas pemantauan pencemaran sungai serta mendukung pengambilan keputusan dalam upaya mitigasi dan penanggulangan pencemaran secara lebih terarah.

3. METODE PENELITIAN

3.1 Desain Penelitian

Penelitian ini dirancang sebagai eksperimental berbasis citra digital dengan pendekatan *supervised learning*. Alur penelitian dimulai dari pengumpulan citra sungai yang mempresentasikan tiga kategori pencemaran (ringan, sedang, dan berat) dilanjutkan dengan *preprocessing* data untuk optimalisasi input model. Tahap inti melibatkan pelatihan arsitektur CNN untuk ekstraksi fitur visual (seperti kekeruhan, perubahan warna, atau keberadaan limbah padat) dan klasifikasi otomatis. Evaluasi model dilakukan menggunakan data testing terpisah untuk mengukur akurasi dan generalisasi. Desain ini dipilih kemampuannya dalam menangani pola kompleks pada data citra dibandingkan metode tradisional.

3.2 Dataset Penelitian

Proses pengambilan data pada penelitian ini dilakukan dengan menggunakan teknik *web scraping* menggunakan Python, yang memanfaatkan Google Images sebagai sumber utama *dataset*. Berikut adalah sintaks yang digunakan dalam melakukan *web scraping*:

```
from icrawler.builtin import
GoogleImageCrawler
keywords = [
    "Slightly murky river with aquatic vegetation",
]

crawler = GoogleImageCrawler(
    storage={"root_dir": folder_path},
    downloader_threads=2,
)

crawler.downloader.session.headers.update({
    "User-Agent": "Mozilla/5.0 (Windows NT
10.0; Win64; x64) AppleWebKit/537.36 (KHTML,
like Gecko) Chrome/91.0.4472.124 Safari/537.36"
})

crawler.crawl(
```

```
keyword=keywords,
max_num=150,
min_size=(200, 200),
max_size=(1920, 1080)
)
```

```
print(f'Gambar tersimpan di: {folder_path}')
```

Dataset yang dikumpulkan terdiri dari citra-citra sungai di Indonesia. Dalam penelitian ini, dataset kemudian akan dibagi ke dalam 2 jenis kondisi kondisi kebersihan sungai sebagai objek klasifikasi, yaitu sungai bersih, sungai tercemar. Total sampel yang berhasil dikumpulkan sebanyak 741 citra, dengan pembagian data sebanyak 592 citra untuk data *training*, 110 citra untuk *validation*, dan 39 citra untuk data *testing*. Pembagian data dilakukan dengan proporsi sekitar 80% untuk data *training*, 15% untuk data *validation*, dan 5% untuk data *testing*.


3.3 Pre-Processing

Setelah proses akuisisi citra selesai, langkah selanjutnya adalah melakukan seleksi citra berdasarkan tingkat kelayakannya sebagai sampel. Karena gambar diperoleh melalui proses *scraping* dari internet, kualitas dan kejelasan citra sangat bervariasi. Oleh karena itu, pemilihan dilakukan secara manual untuk memastikan hanya citra yang menampilkan kondisi sungai dengan jelas yang digunakan dalam tahap selanjutnya. Setelah citra yang layak berhasil diseleksi, gambar-gambar tersebut kemudian dikelompokkan ke dalam dua kategori klasifikasi berdasarkan kondisi kebersihan sungai, yaitu bersih dan tercemar. Kategori “bersih” menunjukkan kondisi sungai dengan air jernih dan lingkungan sekitar yang tidak tercemar, sedangkan kategori “tercemar” mencerminkan sungai yang mulai mengalami pencemaran ringan hingga berat, seperti air yang agak keruh atau terdapat sedikit sampah bahkan air yang tercemar dengan limbah. Sementara itu, pengelompokan ini dilakukan secara manual dan visual untuk mendukung proses klasifikasi pada tahap analisis berikutnya.

3.4 Classification Method


Setelah melakukan tahap *pre-processing*, tahap selanjutnya yaitu melakukan pemodelan. Ada dua model yang digunakan untuk melakukan pemodelan, yaitu *Xception* dan *InceptionV3*.

Xception (*Extreme Inception*) adalah arsitektur jaringan saraf konvolusional yang dikembangkan sebagai pengembangan dari model *Inception* dengan menggunakan teknik *depthwise separable convolution*, sehingga mampu meningkatkan efisiensi dan akurasi dalam klasifikasi citra. Model ini terbukti unggul dalam berbagai penelitian terkini, misalnya pada deteksi penyakit daun padi, *Xception* mampu mencapai akurasi keseluruhan sebesar 93% dan nilai *F1-score* yang tinggi di berbagai kelas penyakit, mengungguli model lain seperti *NASNet Mobile* yang hanya mencapai akurasi 83% [11].



Gambar 1. Arsitektur *Xception*

InceptionV3 adalah arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan untuk meningkatkan kecepatan komputasi dan performa dalam pengenalan gambar. Model ini menggunakan modul *Inception* yang menggabungkan beberapa filter konvolusi dengan ukuran berbeda secara paralel untuk mengekstrak fitur pada berbagai skala, serta menerapkan teknik seperti *batch normalization*, *average pooling*, dan reduksi dimensi menggunakan konvolusi 1x1 untuk mengurangi kompleksitas model dan mencegah *overfitting*. *InceptionV3* juga memanfaatkan data augmentation selama pelatihan dan biasanya dipra-latih pada dataset besar seperti ImageNet untuk mempercepat konvergensi dan meningkatkan akurasi pada tugas klasifikasi spesifik. Model ini telah terbukti efektif dalam berbagai aplikasi, termasuk identifikasi penyakit kulit dengan akurasi tinggi mencapai 99,93% untuk *melanoma* dan 92,26% untuk *basal cell carcinoma* [12].



Gambar 2. Arsitektur *InceptionV3*

3.5 Evaluation

Pada tahap ini, dilakukan evaluasi kinerja model dengan menguji data pada setiap kelas. Tujuan dari pengujian ini adalah untuk menentukan tingkat akurasi terbaik dari masing-masing kelas. Akurasi dihitung sebagai persentase dari total data yang berhasil diidentifikasi dengan benar. Penilaian ini dilakukan menggunakan *Accuracy*, *Confusion Matrix*, *precision*, *recall*, dan *f1-score* [13].

Ukuran penilaian tersebut adalah sebagai berikut :

Confusion Matrix

Confusion Matrix merupakan sebuah metode untuk evaluasi yang menggunakan tabel matriks seperti tabel 2 berikut:

Tabel 1. *Confusion Matrix*

Aktual	Prediksi	
	0	1
0	TN	FP
1	FN	TP

Accuracy (A)

Accuracy adalah rasio prediksi model yang benar dari total prediksi model yang dilakukan. *Accuracy* merepresentasikan seberapa sering model memprediksi kelas yang benar termasuk kelas positif maupun negatif.

$$A = \frac{TP + TN}{TP + TN + FP + FN} \dots (1)$$

Precision (P)

Precision adalah rasio prediksi model kelas positif yang benar dari total prediksi model kelas positif. *Precision* mempresentasikan seberapa sering model memprediksi kelas positif dengan benar diantara total kelas positif.

$$P = \frac{TP}{TP + FP} \dots (2)$$

Recall (R)

Recall adalah rasio prediksi model kelas positif yang benar dari total sampel data kelas positive. *Recall* akan menunjukkan kemampuan model kita untuk mengenali *review* positif yang sebenarnya.

$$R = \frac{TP}{TP + FN} \dots (3)$$

F1-score (F1)

F1-score adalah matrik evaluasi yang menggabungkan *Precision* dan *Recall* dalam memperoleh evaluasi performa yang lebih seimbang.

$$F1 = \frac{2TP}{2TP + FP + FN} \dots (4)$$

4. HASIL DAN PEMBAHASAN**4.1 Confusion Matrix Algoritma Xception**Tabel 2. *Confusion Matrix Algoritma Xception*

Aktual	Prediksi	
	0	1
0	15	2
1	4	18

Keterangan:

0 = Sungai Bersih

1 = Sungai Tercemar

Berdasarkan hasil pengujian model klasifikasi kondisi sungai menggunakan arsitektur *Convolutional Neural Network* (CNN) dengan arsitektur *Xception*, diperoleh *confusion matrix* seperti pada Tabel 2. Dari total 39 data uji, model berhasil mengklasifikasikan 15 data sungai bersih dan 18 data sungai tercemar secara tepat. Namun, terdapat 4 data sungai tercemar yang diklasifikasikan sebagai bersih (*false negative*), serta 2 data sungai bersih yang diklasifikasikan sebagai tercemar (*false positive*).

4.2 Confusion Matrix Algoritma InceptionV3Tabel 3. *Confusion Matrix Algoritma InceptionV3*

Aktual	Prediksi	
	0	1
0	14	3
1	3	19

Keterangan:

0 = Sungai Bersih

1 = Sungai Tercemar

Berdasarkan hasil pengujian model klasifikasi kondisi sungai menggunakan arsitektur *Convolutional Neural Network* (CNN) dengan arsitektur *Xception*, diperoleh *confusion matrix* seperti pada Tabel 2. Dari total 39 data uji, model berhasil mengklasifikasikan 14 data sungai bersih dan 3 data sungai tercemar secara tepat. Namun, terdapat 3 data sungai tercemar yang diklasifikasikan sebagai bersih (*false negative*), serta 19 data sungai bersih yang diklasifikasikan sebagai tercemar (*false positive*).

4.3 Classification Report Algoritma XceptionTabel 4. *Classification Report Arsitektur Xception*

Class	Precision	Recall	F1 Score
0	0.79	0.88	0.83
1	0.90	0.82	0.86
Train Accuracy			83%
Validation Accuracy			84%
Testing Accuracy			85%

Secara keseluruhan, model mencapai akurasi sebesar 85%, dengan nilai *precision* untuk kelas sungai tercemar sebesar 90%, *recall* sebesar 82%, dan *F1-score* sebesar 86%. Nilai *precision* yang tinggi menunjukkan bahwa model cukup andal dalam memastikan bahwa sungai yang diprediksi tercemar memang benar tercemar. Namun demikian, nilai *recall* yang sedikit lebih rendah menunjukkan adanya sejumlah kasus sungai tercemar yang terklasifikasi sebagai bersih. Hal ini menjadi perhatian penting, mengingat klasifikasi yang salah terhadap sungai tercemar sebagai bersih dapat berisiko bagi lingkungan dan masyarakat sekitar.

4.4 Classification Report Algoritma InceptionV3Tabel 5. *Classification Report Arsitektur InceptionV3*

Class	Precision	Recall	F1 Score
0	0.82	0.82	0.82
1	0.86	0.86	0.86
Train Accuracy			87%
Validation Accuracy			79%
Testing Accuracy			85%

Model klasifikasi kondisi sungai menggunakan arsitektur *InceptionV3* menunjukkan performa yang cukup baik berdasarkan metrik evaluasi pada Tabel 4. Untuk kelas 0 (sungai bersih), model memperoleh *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,82. Sementara itu, pada kelas 1 (sungai tercemar), ketiga metrik tersebut menunjukkan nilai yang lebih tinggi, yaitu *precision* 0,86, *recall* 0,86, dan *F1-score* 0,86. Hal ini mengindikasikan bahwa model memiliki performa yang lebih stabil dan akurat dalam mengidentifikasi sungai yang tercemar dibandingkan dengan sungai yang bersih.

Dari sisi akurasi keseluruhan, model mencapai *train accuracy* sebesar 87%, *validation accuracy* 79%, dan *testing accuracy* 85%. Nilai-nilai ini menunjukkan bahwa model tidak mengalami *overfitting* yang

signifikan, karena performa pada data validasi dan data uji relatif konsisten dengan data latih. Akurasi yang tinggi pada data uji memperkuat indikasi bahwa model memiliki kemampuan generalisasi yang baik dalam mengklasifikasikan kondisi sungai berdasarkan citra digital.

Secara umum, penelitian ini membandingkan dua arsitektur *deep learning* berbasis *transfer learning*, yaitu *Xception* dan *InceptionV3*, dalam melakukan klasifikasi kondisi kebersihan sungai berdasarkan citra digital.

Model *Xception* menunjukkan performa yang lebih baik secara keseluruhan, dengan akurasi pengujian sebesar 85%, *precision* dan *recall* yang tinggi untuk kedua kelas, khususnya pada kelas sungai tercemar (*precision* dan *recall* = 0,86). Hasil ini menunjukkan bahwa model *Xception* mampu mengidentifikasi sungai yang tercemar dengan baik, serta memiliki kemampuan generalisasi yang stabil, tercermin dari konsistensi antara akurasi pelatihan, validasi, dan pengujian. Sementara itu, model *InceptionV3* mencatat akurasi pengujian sebesar 85%, dengan performa yang cukup baik namun cenderung lebih rentan terhadap *false negative*, yakni ketika sungai tercemar diklasifikasikan sebagai bersih. Hal ini dapat berisiko dalam konteks pemantauan lingkungan karena pencemaran yang tidak terdeteksi dapat berdampak lebih lanjut terhadap ekosistem dan kesehatan masyarakat.

5. KESIMPULAN DAN SARAN

Dari penerapan 2 algoritma *transfer learning* tersebut dalam klasifikasi kondisi kebersihan sungai berdasarkan citra digital, dapat disimpulkan bahwa *Xception* dan *InceptionV3* sama-sama menunjukkan performa yang baik dalam klasifikasi kondisi kebersihan sungai. Hasil akurasi yang diperoleh dari data uji menunjukkan nilai yang sama besarnya, yaitu 85% baik untuk *Xception* maupun *InceptionV3*, yang menandakan bahwa keduanya mampu mengenali pola visual dengan tingkat akurasi yang hampir setara. Performa serupa ini menunjukkan bahwa baik pendekatan konvolusi standar seperti pada *InceptionV3* maupun *depthwise separable convolution* seperti pada *Xception* sama-sama efektif dalam mengekstraksi fitur penting dari citra sungai. Meski perbedaan akurasi sangat tipis, hal ini tetap membuka peluang untuk eksplorasi lebih lanjut terhadap pengaruh arsitektur model dalam konteks data yang lebih besar dan kompleks. Untuk pengembangan ke depannya, disarankan untuk memperluas *dataset* dengan lebih banyak variasi kondisi sungai, menerapkan teknik augmentasi data untuk meningkatkan generalisasi model, serta memperluas jumlah kelas klasifikasi agar sistem lebih rinci dalam menilai kualitas sungai. Selain itu, eksperimen lebih lanjut seperti *fine-tuning* hyperparameter atau eksplorasi arsitektur lain seperti *EfficientNet*, serta metode *ensemble*, dapat menjadi langkah strategis

untuk meningkatkan akurasi dan kestabilan sistem dalam berbagai kondisi nyata di lapangan.

DAFTAR PUSTAKA

- [1] Y. Witsqa Firmansyah et al., "Kondisi Sungai di Indonesia Ditinjau dari Daya Tampung Beban Pencemaran: Studi Literatur," *Serambi Engineering*, vol. VI, no. 2, 2021.
- [2] S. Fibriani, dan D. Ayuningrum, "Analysis of Water Quality Status and Pollution Load of Siangker River," *Jurnal Pasir Laut* vol. 5, no. 2, pp. 78–86, 2021.
- [3] C. Eva Sari Nainggolan et al., "Perbandingan Klasifikasi Jenis Sampah Menggunakan Convolutional Neural Network Dengan Arsitektur ResNet18 dan ResNet50 The Classification Comparison of Waste Type Using Convolutional Neural Network by Resnet18 and Resnet50 Architecture," vol. 16, no. 1, p. 76, 2024, doi: 10.22303/csrid.1.1.2022.01-10.
- [4] A. Y. Setyawan, T. Surabaya, and Y. Kristian, "River Cleanliness Measured on Lots of Waste Based on Digital Image Processing Using a Deep Convolutional Neural Network Penentuan Tingkat Kebersihan Sungai Berdasarkan Banyak Sampah Berbasis Pengolahan Citra Digital Menggunakan Deep Convolutional Neural Network," October, 2020.
- [5] M. T. Ali S. A. dan B. Sugiarto, "Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Ikan Cupang Berbasis Mobile," *Digital Transformation Technology (Digitech)*, vol. 3, no. 2, pp. 712–723, Sep. 2023, doi: 10.47709/digitech.v3i2.3245.
- [6] R. Adityatama and A. T. Putra, "Image Classification of Human Face Shapes Using Convolutional Neural Network Xception Architecture with Transfer Learning," *Recursive Journal of Informatics*, vol. 1, no. 2, pp. 102–109, Sep. 2023. doi: 10.15294/rji.v1i2.70774.
- [7] R. Theofilus dan R. Kurniawan, "Deteksi sampah di permukaan sungai menggunakan Convolutional Neural Network dengan algoritma YOLOv8: Studi kasus Sungai Ciliwung," *Seminar Nasional Official Statistics 2024*, pp. 537–548, 2024.
- [8] M. A. Pramanik, A. A. Biswas, M. A. Z. Khan, dan M. M. Rahman, "Lemon leaf disease classification using CNN-based architectures with transfer learning," dalam *12th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, 2021, pp. 1–7.
- [9] X. Liu, Z. Yu, dan L. Tan, "Deep learning for lung disease classification using transfer learning and a customized CNN architecture with attention," *arXiv preprint*, arXiv:2408.13180v1, 2024.

- [10] U. Amin, M. I. Shahzad, A. Shahzad, M. Shahzad, U. Khan, dan Z. Mahmood, "Automatic fruits freshness classification using CNN and transfer learning," *Applied Sciences*, vol. 13, p. 8087, 2023.
- [11] E. Turnip dan A. F. Rozi, "Analisis Perbandingan Arsitektur Convolutional Neural Network pada Klasifikasi Jenis Penyakit Daun Padi," *Jurnal ProTekInfo*, vol. 11, no. 2, pp. 1-8, Agustus 2024.
- [12] A. W. Kosman dan Y. Darma, "Pengujian Metode Inception V3 dalam Mengidentifikasi Penyakit Kanker Kulit," *Jurnal Teknologi Informatika dan Komputer MH. Thamrin*, vol. 10, no. 1, pp. 140-150, Mar. 2024.
- [13] R. Indransyah, Y. H. Chrisnanto, and P. N. Sabrina, "Klasifikasi sentimen pergelaran MotoGP di Indonesia menggunakan algoritma Correlated Naïve Bayes Classifier," *INFOTECH Journal*, vol. 8, no. 2, pp. 60–66, Dec. 2022. DOI: 10.31949/infotech.v8i2.3103.