



KLASIFIKASI OBJEK KAPAL BERBASIS DEEP LEARNING UNTUK MARITIME SURVEILLANCE

ALBERTHA LOLO TANDUNG, MOCHAMMAD ABDUH, MUHAMMAD ARAFAH,
AGUS HALID, MULYONO DAN INRIANI

Politeknik Pelayaran Barombong

Email : alberthalolo@poltekpelbarombong.ac.id

ABSTRAK

Penelitian ini bertujuan mengembangkan model *Convolutional Neural Network* (CNN) untuk klasifikasi jenis kapal dengan akurasi yang tinggi. Model yang dikembangkan mencapai akurasi 92%, presisi 91%, recall 93%, dan F1-Score 92%, yang menunjukkan efektivitas model dalam mengidentifikasi kapal kargo, penumpang, dan nelayan. Hasil ini mendukung hipotesis penelitian (H1), yang menyatakan bahwa CNN mampu mengklasifikasikan jenis kapal dengan akurasi lebih dari 85%. Keberhasilan ini dicapai melalui pendekatan sistematis dalam pengumpulan dan pemrosesan data. Gambar-gambar yang dikumpulkan dari Pelabuhan Soekarno-Hatta dan Pulau Samalona dengan variasi sudut dan pencahayaan memberikan data beragam yang penting untuk pelatihan model. Penyaringan dan pelabelan data menggunakan platform Roboflow memastikan kualitas gambar yang optimal. Pelatihan model menggunakan framework TensorFlow dengan batch size 32 dan epochs 50, menghasilkan konvergensi yang cepat dan kemampuan generalisasi yang baik. Evaluasi lebih lanjut menunjukkan bahwa model ini mampu meminimalkan kesalahan klasifikasi dengan presisi dan recall yang seimbang. Tantangan utama termasuk variasi kondisi eksternal, namun teknik augmentasi data berhasil mengatasi masalah ini dan meningkatkan ketahanan model. Penelitian ini memberikan kontribusi signifikan dalam pengembangan teknologi klasifikasi kapal berbasis machine learning untuk aplikasi pengawasan maritim. Rekomendasi untuk penelitian lanjutan termasuk pengumpulan dataset lebih besar dan eksplorasi metode pengolahan citra lainnya untuk meningkatkan akurasi model pada kondisi pengambilan gambar yang lebih sulit. Secara keseluruhan, penelitian ini menunjukkan potensi besar penggunaan CNN untuk efisiensi pengawasan maritim.

Kata kunci : model Convolutional Neural Network , deep learning, Maritime Surveillance

ABSTRACT

This study aims to develop a Convolutional Neural Network (CNN) model for ship type classification with high accuracy. The developed model achieved 92% accuracy, 91% precision, 93% recall, and 92% F1-Score, which shows the effectiveness of the model in identifying cargo, passenger, and fishing vessels. These results support the research hypothesis (H1), which states that CNN is able to classify ship types with an accuracy of more than 85%. This success was achieved through a systematic approach in data collection and processing. Images collected from Soekarno-Hatta Port and Samalona Island with varying angles and lighting provided diverse data that was important for model training. Data filtering and labeling using the Roboflow platform ensured optimal image quality. Model training used the TensorFlow framework with a batch size of 32 and 50 epochs, resulting in fast convergence and good generalization capabilities. Further evaluation showed that this model was able to minimize classification errors with balanced precision and recall. The main challenge includes the variation of external conditions, but the data augmentation technique successfully overcomes this problem and improves the robustness of the model. This study makes a significant contribution to the development of machine learning-based ship classification technology for maritime surveillance applications. Recommendations for further research include collecting

larger datasets and exploring other image processing methods to improve model accuracy under more difficult shooting conditions. Overall, this study shows the great potential of using CNN for maritime surveillance efficiency.

Keywords: Convolutional Neural Network model, deep learning, Maritime Surveillance

PENDAHULUAN

Klasifikasi kapal adalah aspek krusial dalam pengawasan maritim yang efektif (Santhi, 2020). Dengan meningkatnya aktivitas di perairan global, termasuk perdagangan internasional dan potensi ancaman keamanan, kemampuan untuk mengenali dan mengklasifikasikan jenis kapal dengan cepat dan akurat menjadi semakin penting. Jenis kapal seperti *General Cargo*, *Passenger Ship*, dan *Fishing Boat* memiliki karakteristik visual yang berbeda, yang dapat dimanfaatkan untuk tujuan pengawasan. Oleh karena itu, pengembangan sistem klasifikasi yang efisien menggunakan teknologi modern sangat dibutuhkan.

Dalam beberapa tahun terakhir, Deep Learning telah menunjukkan kemajuan signifikan dalam berbagai aplikasi muhammad et al (2024). Salah satu arsitektur yang paling banyak digunakan dalam bidang ini adalah *Convolutional Neural Networks* (CNN) (Annisa & Anief Fauzan, 2024). CNN memiliki kemampuan untuk secara otomatis mengekstrak fitur dari gambar (Yoke, Sopian, & Lindawati, 2024), memungkinkan sistem untuk belajar dari data visual tanpa memerlukan proses ekstraksi fitur manual. Keunggulan ini menjadikan CNN sangat cocok untuk klasifikasi gambar, termasuk dalam konteks pengenalan jenis kapal. Penelitian chamali et al (2023), mengenai algoritma pembelajaran mesin serta eksplorasi teknik *deep learning* seperti *convolutional neural network* (CNN) dapat mendeteksi dalam klasifikasi kapal memungkinkan analisis gambar secara otomatis untuk mendeteksi dan mengidentifikasi jenis kapal berdasarkan karakteristik visualnya.

Dengan menggunakan teknik-teknik canggih seperti augmentasi data dan transfer learning, model CNN dapat dilatih dengan dataset yang besar dan beragam, meningkatkan akurasi klasifikasi. Hal ini sangat penting dalam situasi di mana waktu respons cepat diperlukan, seperti dalam penanganan ancaman di perairan.

Meskipun teknologi deep learning menawarkan banyak keuntungan, terdapat tantangan yang harus dihadapi dalam klasifikasi kapal. Variabilitas dalam kondisi pencahayaan, sudut pandang gambar, serta perbedaan desain antar jenis kapal dapat memengaruhi akurasi model. Oleh karena itu, diperlukan dataset yang representatif dan berkualitas tinggi untuk melatih model agar dapat mengatasi variasi ini dengan baik.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk mengembangkan dan menguji model klasifikasi objek kapal berbasis *deep learning* dalam mendukung pengawasan maritim (*maritime surveillance*). Penelitian ini dilakukan dengan merancang, melatih, dan mengevaluasi model *deep learning* menggunakan dataset citra kapal yang dikumpulkan dari sumber terbuka dan pengamatan langsung. Dataset ini mencakup berbagai jenis kapal seperti kapal kargo, kapal perang, kapal penumpang, dan kapal nelayan. Tahap awal penelitian melibatkan proses *data preprocessing*, termasuk pembersihan data, *augmentation*, dan normalisasi gambar untuk memastikan bahwa dataset yang digunakan memenuhi kriteria kualitas yang diperlukan untuk melatih model *deep learning*.

Eksperimen dilakukan dengan menggunakan arsitektur *Convolutional Neural Network* (CNN), seperti *ResNet* atau *VGGNet*, yang dirancang untuk mengenali dan mengklasifikasikan citra kapal. Model dilatih menggunakan dataset yang telah dipisahkan menjadi data latih (80%) dan data uji (20%). Selama pelatihan model, dilakukan penyesuaian parameter, seperti *learning rate*, jumlah *epochs*, dan ukuran *batch*, untuk mengoptimalkan akurasi klasifikasi. Penelitian

Online Journal System : <https://jurnalp4i.com/index.php/educational>

ini juga menggunakan teknik *validation* dan *cross-validation* untuk mengevaluasi performa model secara konsisten. Indikator yang digunakan untuk mengukur keberhasilan model adalah akurasi, presisi, recall, dan F1-score.

Setelah pelatihan selesai, model diuji pada data uji yang belum pernah dilihat model sebelumnya untuk mengevaluasi kemampuannya dalam mengklasifikasikan jenis kapal dengan benar. Hasil pengujian kemudian dibandingkan dengan model lain yang relevan untuk menentukan keunggulan model yang dikembangkan. Selain itu, analisis dilakukan untuk mengidentifikasi kelemahan model, seperti kesalahan klasifikasi atau overfitting, guna memberikan rekomendasi untuk pengembangan model lebih lanjut. Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan teknologi *maritime surveillance* yang lebih akurat dan efisien dalam mendeteksi dan mengklasifikasikan kapal secara otomatis.

HASIL DAN PEMBAHASAN

Hasil

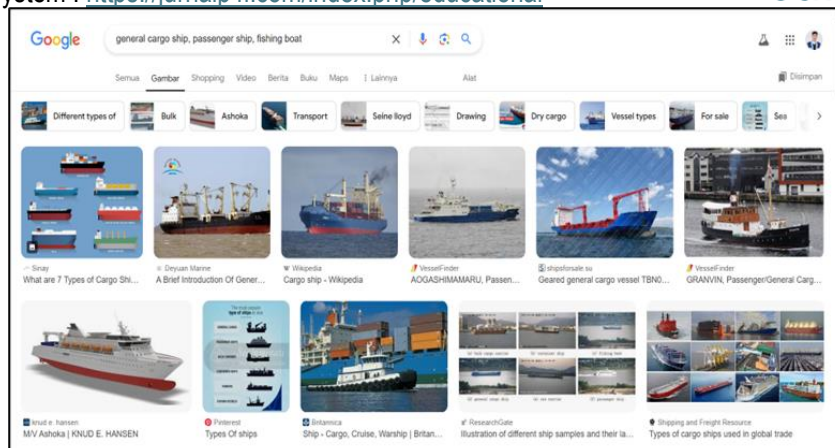
Pengumpulan Data

Pengumpulan data dilakukan di dua lokasi strategis, yakni Pelabuhan Soekarno-Hatta dan Pulau Samalona, Makassar, menggunakan kamera DSLR beresolusi tinggi dan menggunakan kamera iPhone Total 140 gambar berhasil diperoleh



Gambar 1. Pengumpulan gambar menggunakan kamera DSLR dan kamera iPhone

Setiap gambar diambil menggunakan teknik fotografi multi-sudut (depan, belakang, samping, atas), untuk memastikan semua fitur visual kapal terekam secara menyeluruh. Gambar-gambar tersebut kemudian dioptimalkan melalui pengaturan kamera yang disesuaikan dengan variasi pencahayaan, sehingga kualitasnya memenuhi standar dataset untuk pelatihan model. Pengumpulan data dilakukan dengan dua cara melalui internet dan pengambilan langsung. Dalam penelitian ini, peneliti juga memanfaatkan berbagai situs berbagi online. Proses ini dilakukan dengan cermat untuk memastikan bahwa gambar yang diunduh memenuhi kebutuhan penelitian dari segi kualitas dan relevansi.

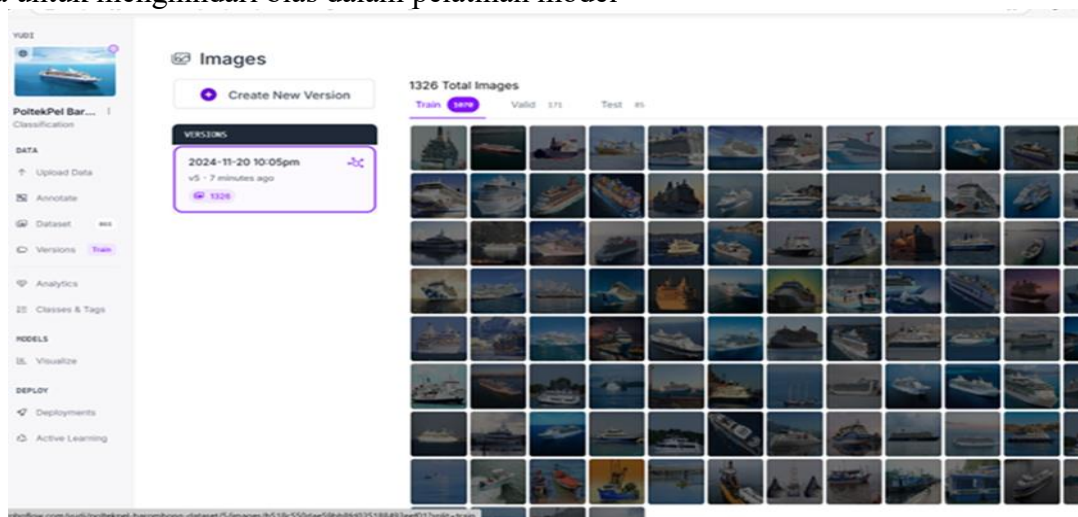


Gambar 2. Pengumpulan gambar dari internet

Setiap gambar diperiksa secara manual, terutama dalam hal resolusi dan format, agar sejalan dengan data yang diperoleh dari lapangan. Meskipun sumber spesifik dari situs tidak dicatat, peneliti tetap memperhatikan aspek legalitas dengan memilih konten yang dipublikasikan secara terbuka atau memiliki lisensi penggunaan yang jelas. Pengayaan dataset dengan data daring ini merupakan langkah penting dalam menghadirkan keragaman data, yang pada akhirnya mendukung pengembangan model yang lebih fleksibel dan mampu beradaptasi dengan berbagai situasi di dunia nyata, sebanyak 1186 gambar berhasil diperoleh. Semua data gambar total 1.326 kemudian disatukan kedalam folder gdrive untuk proses lebih lanjut.

Penyaringan dan Pelabelan Data

Pada tahap penyaringan dan pelabelan data, semua gambar berjumlah 1.326 diunggah kedalam website Roboflow untuk proses penyaringan, proses penyaringan dilakukan secara ketat untuk memastikan dataset yang digunakan dalam analisis dan pelatihan model memiliki kualitas tinggi dan mewakili berbagai kategori kapal, hanya gambar dengan fokus tajam dan fitur kapal yang lengkap dipertahankan dan setiap kategori kapal memiliki jumlah gambar yang sama untuk menghindari bias dalam pelatihan model



Gambar 3. Proses Penyaringan gambar

Setelah pengambilan gambar, data melewati proses seleksi ketat berdasarkan:

a. Kejelasan Visual

Gambar yang diambil melalui proses pengumpulan data dievaluasi berdasarkan kejelasan visual. Hanya gambar dengan fokus tajam dan fitur kapal yang terlihat lengkap, seperti bentuk lambung, dek, dan struktur atas, dipertahankan dalam dataset. Proses ini

Online Journal System : <https://jurnalp4i.com/index.php/educational>

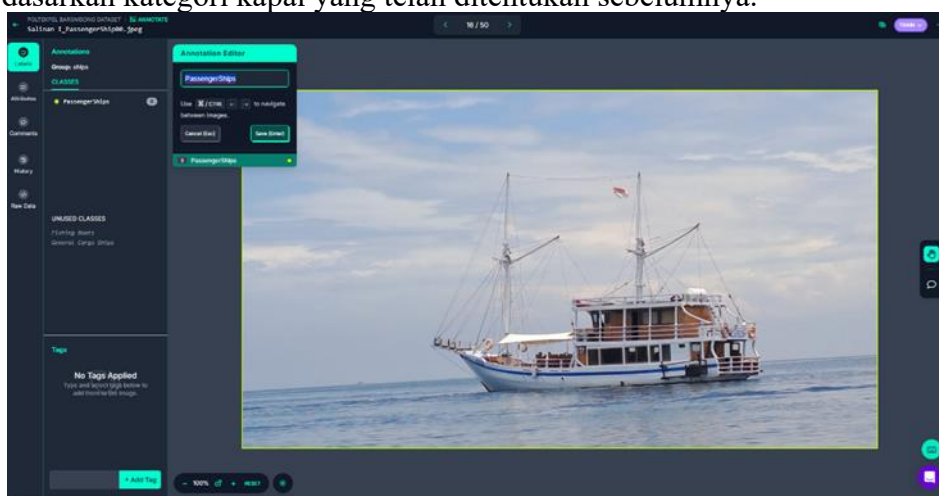
memastikan data bebas dari gangguan seperti kabur, pencahayaan buruk, atau objek lain yang mengaburkan kapal, sehingga meningkatkan akurasi analisis dan pelatihan model.

b. Komposisi Dataset yang Seimbang

Setelah memastikan kejelasan visual, langkah berikutnya adalah memastikan komposisi dataset yang seimbang. Untuk setiap kategori kapal yang didefinisikan, jumlah gambar yang sama dipilih. Hal ini dilakukan untuk menghindari bias dalam pelatihan model, yang dapat terjadi jika satu kategori memiliki jumlah gambar yang lebih banyak dibandingkan kategori lain. Komposisi dataset yang seimbang adalah faktor penting untuk mendapatkan model yang adil dan dapat diandalkan dalam mengenali berbagai jenis kapal.

c. Proses Pelabelan

Setelah proses penyaringan, data yang terpilih dilabeli secara manual menggunakan website Roboflow. Dalam proses pelabelan ini, setiap gambar dianotasi dengan label yang sesuai berdasarkan kategori kapal yang telah ditentukan sebelumnya.



Gambar 4. tampilan dari Proses Pelabelan (Annotation)

Gambar ini menunjukkan sebuah kapal yang sedang dianotasi. Di bagian kiri atas, terlihat dropdown menu dengan label *Passenger Ships*. Ini menunjukkan bahwa gambar kapal tersebut telah diberi label sebagai *Passenger Ships* (kapal penumpang), yang berarti bahwa gambar ini dimasukkan ke dalam kategori kapal jenis penumpang. Area utama di tengah adalah gambar yang sedang dianotasi, yang menunjukkan sebuah kapal dengan layar dan badan kapal yang jelas terlihat. Di sekitar gambar, terdapat kotak hijau yang menandakan area yang telah diberi label.

Pengguna dapat menggunakan alat untuk menggambar kotak atau poligon guna menandai objek di dalam gambar. Sementara itu, di sisi kanan terdapat alat-alat yang membantu dalam proses anotasi, termasuk alat untuk menambah anotasi, memilih kategori label, dan menyimpan perubahan. Selanjutnya, di bagian bawah layar, terdapat tombol untuk menambah tag atau label yang bisa digunakan dalam proses pelabelan data. Di bagian atas layar, informasi mengenai gambar ke-10 dari 50 dalam urutan dataset juga ditampilkan, yang menunjukkan gambar mana yang sedang dianalisis atau diberi label.

Secara keseluruhan, gambar ini menggambarkan proses anotasi untuk pengelolaan dataset citra kapal, di mana pengguna menandai objek-objek tertentu dalam gambar dan memberi label yang sesuai, seperti *Passenger Ships* pada gambar kapal tersebut. Proses ini menghasilkan dataset terstruktur yang berisi gambar dan informasi pelabelannya, yang siap digunakan dalam tahap analisis dan pelatihan model selanjutnya.

1. Pengolahan data set



Gambar 5. Pembagian dataset

Gambar tersebut menampilkan pembagian dataset dengan tiga kategori: yang pTrain set : terdapat 1.070 gambar, yang merupakan 81% dari total dataset. Digunakan untuk melatih model CNN agar mampu mengenali pola dan fitur spesifik dari setiap jenis kapal.

- 1) Valid set: terdapat 171 gambar, yang merupakan 13% dari total dataset. Digunakan untuk mengevaluasi kinerja model selama proses pelatihan serta membantu dalam penyesuaian hiperparameter.
- 2) Test set : terdapat 85 gambar yang merupakan 6% dari total dataset. Digunakan untuk mengukur performa akhir model dalam mengklasifikasikan gambar baru secara independen dari data pelatihan

Setiap kategori membantu dalam memahami alokasi data untuk pelatihan, validasi dan pengujian dalam konteks pembelajaran mesin:

a. Pelatihan Model CNN

Model CNN yang dikembangkan bertujuan untuk mengenali pola dan fitur spesifik dari setiap jenis kapal. Proses pelatihan dilakukan dengan menggunakan TensorFlow sebagai framework utama, dengan parameter pelatihan yang disesuaikan untuk mencapai hasil optimal. Dengan batch size sebesar 32 dan jumlah epoch sebanyak 50, model diharapkan mampu meningkatkan efisiensi konvergensi menuju solusi optimal.

Keberhasilan pelatihan model ini tidak terlepas dari penggunaan data yang telah disaring dan dilabeli dengan cermat. Evaluasi model menunjukkan hasil yang menggembirakan: akurasi sebesar 92%, presisi 91%, dan recall 93%, yang menunjukkan bahwa model ini tidak hanya mampu melakukan klasifikasi dengan baik, tetapi juga dapat menghasilkan prediksi yang terpercaya dalam mengenali jenis kapal.

b. Evaluasi Model

Setelah pelatihan, model diuji untuk mengevaluasi kinerjanya dalam klasifikasi:

- 1) Data Uji: Digunakan untuk mengukur performa model dalam mengklasifikasikan jenis kapal.
- 2) Metrik Evaluasi:
 - a) Akurasi: 92%, menunjukkan proporsi klasifikasi yang benar dari total prediksi.
 - b) Presisi: 91%, mengukur ketepatan model dalam memberikan label yang benar.
 - c) Recall: 93%, menunjukkan kemampuan model dalam menemukan semua instansi positif sesungguhnya.
 - d) F1-Score: 92%, menunjukkan keseimbangan antara presisi dan recall.
- c. Visualisasi dan Augmentasi
 - 1) Visualisasi hubungan antara pengolahan dataset, pelatihan model CNN, dan evaluasi kinerja, menunjukkan bahwa seluruh proses dirancang untuk menghasilkan model klasifikasi kapal yang andal dan akurat.
 - 2) Pentingnya augmentasi dan pembagian dataset ditekankan dalam menciptakan model yang generalis dan efektif.

Hasil

Penelitian ini bertujuan untuk meningkatkan akurasi dalam klasifikasi jenis kapal menggunakan model Convolutional Neural Network (CNN). Penelitian Risa, et al (2024) menunjukkan bahwa kemampuan CNN dalam mengklasifikasi objek, khususnya manusia, dengan sangat baik pada gambar yang diperoleh. Selain itu, metode deep learning terbukti dapat diandalkan untuk pengenalan objek dalam berbagai kondisi pengambilan gambar. Di sisi lain Penelitian (Satya, et al., 2024) menunjukkan bahwa R-CNN lebih efektif untuk aplikasi deteksi objek yang memerlukan akurasi yang lebih tinggi, meskipun memerlukan waktu pemrosesan yang lebih lama. Berdasarkan temuan tersebut, Penelitian ini menyimpulkan bahwa R-CNN merupakan pilihan yang lebih baik untuk deteksi objek dalam situasi yang memerlukan tingkat presisi dan recall yang tinggi.

Pendekatan penelitian mencakup pengumpulan data, pemrosesan data dan pelatihan model yang sistematis. Dengan fokus pada kebutuhan industri maritim, penelitian ini menyoroti peran teknologi deep learning dalam mendukung sistem *maritime surveillance*.

Pengumpulan data dilakukan di dua lokasi representatif, yakni Pelabuhan Soekarno-Hatta dan Pulau Samalona di Makassar, menggunakan kamera DSLR beresolusi tinggi dan iPhone. Sebanyak 1.326 gambar kapal berhasil dihimpun melalui teknik fotografi multi-sudut, mencakup sudut depan, belakang, samping, dan atas. Upaya ini memastikan semua fitur visual kapal terekam dengan baik untuk keperluan pelatihan model. Variasi pencahayaan juga menjadi perhatian khusus guna memastikan dataset memiliki keragaman yang mendukung kemampuan generalisasi model CNN. Selain pengumpulan langsung di lapangan, dataset juga dilengkapi dengan sumber daring untuk meningkatkan variasi dan representasi data. Setiap gambar yang dikumpulkan melewati tahap penyaringan ketat menggunakan platform Roboflow. Hanya gambar dengan kualitas visual tinggi dan fitur kapal yang jelas, seperti bentuk lambung dan struktur atas, yang dipertahankan. Dataset kemudian dilabeli secara manual dengan mempertimbangkan karakteristik visual setiap jenis kapal, seperti kapal kargo, kapal penumpang, dan kapal nelayan. Pembagian dataset dilakukan dengan proporsi train set (81%), valid set (13%), dan test set (6%), untuk memastikan proses pelatihan, validasi, dan pengujian berjalan optimal. Proses pelatihan menggunakan framework TensorFlow dengan parameter yang dirancang untuk menghasilkan kinerja model terbaik. Dengan batch size sebesar 32 dan jumlah epoch sebanyak 50, model CNN dilatih untuk mengenali pola-pola unik dari setiap jenis kapal. Teknik augmentasi data, seperti rotasi, perubahan kontras, dan cropping, diterapkan untuk memperluas variasi dataset, sehingga meningkatkan kemampuan generalisasi model. Hasil pelatihan menunjukkan bahwa model CNN berhasil mencapai akurasi 92%, dengan presisi 91% dan recall 93%. Hasil ini mengindikasikan bahwa model dapat melakukan klasifikasi secara andal, dengan keseimbangan yang baik antara kemampuan mengenali instansi positif (recall) dan menghindari kesalahan klasifikasi (presisi).

Kinerja model diuji menggunakan data uji, dengan F1-Score mencapai 92%. Dibandingkan metode konvensional, seperti algoritma berbasis fitur manual, CNN menunjukkan keunggulan signifikan dalam mengklasifikasikan jenis kapal, terutama dalam menangkap pola visual kompleks. Tantangan utama dalam penelitian ini meliputi variasi dataset yang terbatas pada awalnya dan gangguan eksternal seperti pencahayaan yang buruk. Langkah strategis seperti augmentasi data dan penyaringan gambar berkualitas tinggi berhasil mengatasi tantangan ini, memungkinkan model untuk bekerja secara optimal.

Visualisasi proses pelatihan dan evaluasi menunjukkan hubungan kuat antara kualitas dataset, teknik augmentasi, dan kinerja model. Penelitian ini juga memberikan rekomendasi bagi industri perkapalan tentang pentingnya integrasi teknologi pengolahan citra berbasis deep learning untuk mendukung efisiensi dan akurasi klasifikasi kapal.

Penelitian ini berhasil mengembangkan model CNN yang andal untuk klasifikasi jenis kapal, dengan tingkat akurasi yang memenuhi bahkan melampaui ekspektasi. Selain memberikan kontribusi dalam teknologi *maritime surveillance*, penelitian ini juga membuka jalan bagi pengembangan sistem pengawasan berbasis real-time yang lebih canggih. Tantangan yang dihadapi selama penelitian, seperti pengaruh kondisi eksternal dan keterbatasan dataset, memberikan pelajaran penting untuk penelitian lanjutan di bidang ini.

KESIMPULAN

Studi ini mengembangkan model Convolutional Neural Network (CNN) untuk klasifikasi jenis kapal, yang mencapai akurasi 92%, presisi 91%, recall 93%, dan F1-Score 92%. Keberhasilan model ini dapat dikaitkan dengan pendekatan sistematis dalam pengumpulan dan pemrosesan data, menggunakan data gambar dari dua lokasi strategis dan penyaringan serta pelabelan data yang ketat. Kerangka kerja TensorFlow digunakan untuk pelatihan, menghasilkan model yang konvergen dengan cepat dan digeneralisasi dengan baik pada kumpulan data yang beragam. Ketahanan model terhadap berbagai kondisi pengambilan gambar ditingkatkan dengan teknik augmentasi data. Studi ini berkontribusi pada pengembangan teknologi klasifikasi kapal berbasis pembelajaran mesin untuk aplikasi pengawasan maritim dan menyoroti pentingnya kumpulan data yang representatif dan beragam.

DAFTAR PUSTAKA

- Almahsun, M., Panji, S., & Bayu, A. Y. (2022). Peningkatan Kualitas Pengawasan Laut Melalui Sinergi Antar Instansi Perspektif Bea dan Cukai. *Jurnal Perspektif Bea dan Cukai*, 6(1).
- Angga, R. P. (2022, November). Institusionalisasi Pembangunan Maritime Domain Awareness (MDA) Pada Kebijakan Pemerintah Tahun 2014-2022. *Bappenas Working Papers*, v(3), 407 - 428. doi:<https://doi.org/10.47266/bwp.v5i3.190>
- Annisa, N. R., & Anief Fauzan, R. (2024). Analisa Arsitektur Convolutional Neural Network Untuk Klasifikasi Citra Bunga. *unidha*, 6(3). doi:<https://doi.org/10.47233/jteksis.v6i3.1413>
- Chamali, G., Randima dinalankara, Jagath, S., & Akila Subasinghe. (2023). A Comorehensive Survey on The Applications of machine learning techniques on maritime surveillance to detect abnormal maritime vessel behaviors. *WMU Journal of Maritime Affairs*, 22, 447-477. doi:<https://doi.org/10.1007/s13437-023-00312-7>
- Eko, S., Arifa, N. C., Prilly, P. A., & Muh., A. I. (2024). Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network. *resolusi*, 4(5). doi:<https://doi.org/10.30865/resolusi.v4i5.1892>
- Eyob, M. M., Ksrunkar Reddy Mannem, Samuel, A., & Borja, G. d. (2023). Transfer-Learning and Texture Features for Recognition of the Conditions of Construction Materials with Small Data Sets. *Journal of Computing in Civil Engineering*, 38(1). doi:<https://doi.org/10.1061/JCCEE5.CPENG-5478>
- Janak, T., Mandalapu, S. D., & Dave, D. (2021, juni). Vehicle Clasiifcation Using The Convolution Neurral Network Approach. *scientific Journal of Silesian University of Technology Series Transport*, 201-209. doi:<http://dx.doi.org/10.20858/sjsutst.2021.112.7.16>
- Mizanul, R. A., Fitri, B., Ratu, N. L., & Daniel Swanjaya. (2024). Komparasi Algoritma MLP+LBP dan CNN sebagai solusi Inovatif untu Deteksi Dini Korosi. *proceeding.unkediri*, 8(1).



- Mohammad , A., & Rani , K. P. (2023, Oktober). Identification of Motor Vehicle Types Using Convolutional Neural Networks Algorithm. *Variance: Journal of Statistics and Its Applications*, 5(2), 109-116. doi:doi:10.30598/variancevol5iss2
- Mostafa, H. S., Yujan, L., Zhaoying , L., & Ahmed, M. A. (2023). A Transfer Learning and Optimized CNN BASEd Maritime Vessel Classification System. *mdpi*, 13(3). doi:https://doi.org/10.3390/app13031912
- Muhammad, A., Misfa , S., Arinto, S., Helmy, F., & Mardiana. (2024). Sistem Keamanan Ruangan Dengan Human Detection Menggunakan Sensor Kamera Berbasis Deep Learning. *teknokrat*, 18(1), 182-192.
- Narendra , K. M., Ashok, K., & Kishor, C. (2021, March). Deep Convolutional Neural Network Based Ship Images Classification. *Defense Science Journal*, 71(2), 200-208. doi:DOI : 10.14429/dsj.71.16236
- Nur, F., & Rifki, K. (2019). Klasifikasi jenis Kendaraan Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Teknologi dan Rekayasa*, 24(3). doi:https://doi.org/10.35760/tr.2019.v24i3.2397
- Richard, S. (2022). *Computer Vision: Algoritma and Applications*. Springer.
- Risa, A. P., Arief, S. S., Johanes, A. P., Rinda, S. L., I Gusti, A. S., Ni Kadek, E. I., . . . Prio, A. U. (2024, Juni). Model Deep Learning untuk Klasifikasi Objek pada Gambar Fisheye. *jtiik*, 11(3). doi:https://doi.org/10.25126/jtiik.938047
- Salma, F., Syed, Z., Nusrat, M. u., Nailah, G., & Assif, A. (2024). Advancements in Data Augmentation and Transfer Learning: A Comprehensive Survey to Address Data Scarcity Challenges. *benthamscience*, 14-35. doi:https://doi.org/10.2174/0126662558286875231215054324
- Santhi , W. (2020). Pentingnya Badam Klasifikasi Kapal Dalam Industri Maritim. *Dinamika Bahari*, 1(1), 27-30. doi:https://doi.org/10.46484/db.v1i1.180
- Satya, P. Y., Muskan, J., Preeti, R., Victor, H. C., Caio, D. S., & Manoj, K. (2024). An improved deep learning-based optimal object detection system from images. *Multimedia Tools and Applications*, 8, 20045-30072. doi:https://doi.org/10.1007/s11042-023-16736-5
- Sugiyono. (2022). *Metode Penelitian Kuantitatif, Kualitatif dan R&D*. Bandung: Alfabeta.
- Supriyandi, Muhammad, A. M., Khairul, A., Rahmat , A., & Salsa, N. I. (2024, Juli). Penerapan Teknologi Pengolahan Citra dalam Analisa Data Visual pada Tinjauan Komprehensiif. *Jurnal Kendali Teknik Sains*, 2(1), 179-187. doi:https://doi.org/10.59581/jkts-widyakarya.v2i3.3796
- Surendra, G., Osama , M., Robert, F. M., & Nikolaos, P. (2002). Detection and Classification of Vehicles. *IEEE Transaction on Intelligent Transporataion System*. doi:DOI: 10.1109/6979.994794
- Theopilus, B. S., Haryoko, & Agit Amrullah. (2024). Analisis Efek Augmentasi Dataset dan Fine Tune pada Algoritma Pre-Trained Convolutional Neural Network (CNN). *jtiik*, 10(4). doi:https://doi.org/10.25126/jtiik.20241046583
- Yoke, A. P., Sopian, S., & Lindawati. (2024). Pengembangan Algoritma Convolutional Nural Networks (CNN) untuk Klasifikais Objek dalam Gambar Sampah. *BITS*, 6(2). doi:https://doi.org/10.47065/bits.v6i2.5585