

Optimizing Data Augmentation Parameters in YOLOv11 for Enhanced Rip Current Detection on Small Datasets from Depok-Parangtritis Coastline

Madina Hayva Putri^{*1}, Umar Zaky², Bayu Argadyanto Prabawa³

¹Informatics, Universitas Teknologi Yogyakarta, Indonesia

²Information Systems, Universitas Teknologi Yogyakarta, Indonesia

³Urban and Regional Planning, Universitas Teknologi Yogyakarta, Indonesia

Email: ¹yvamadina@email.ac.id

Received : Sep 29, 2025; Revised : Oct 18, 2025; Accepted : Oct 19, 2025; Published : Oct 23, 2025

Abstract

Rip currents are powerful ocean currents that can suddenly pull swimmer offshore and are often difficult to recognize visually. However, automatic monitoring technology for detecting rip currents is still limited, while small datasets often lead to overfitting problems and reduce detection accuracy. This study aims to optimize data augmentation parameters in YOLOv11 to improve the mean Average Precision (mAP) value and enable rip current detection even with limited data. The dataset was collected from Google Earth and aerial photographs from the Depok-Parangtritis coastline. Preprocessing includes manual labelling, cropping, and resizing to 640 x 640 pixels. Four augmentation techniques were applied, namely crop (0-10%), rotation (-10% to +10%), brightness adjustment (-10% to +10%), and 1 pixel blur using Roboflow. The dataset was split into 70% training and 30% validation. The YOLOv11 model was then trained and evaluated with precision, recall, and mAP metrics. Results show that data augmentation significantly improves model performance. Dataset 2 without augmentation achieved only 31.8% precision, 32.8% recall, and 23.8% mAP50, while the best model from a combination of the original Dataset 1 and the augmented Dataset 3 reached 90.6% precision, 85.7% recall, and 90.4% mAP50. The integration of YOLOv11 into a web application enables automatic detection in both images and videos with bounding box and confidence score. This study emphasizes the importance of visual variation in the dataset for improving the model generalization and provide a practical foundation of real-time coastal monitoring system.

Keywords : Data Augmentation, Deep Learning, Object Detection, Rip Current, Small Datasets, YOLOv11.

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



1. PENDAHULUAN

Destinasi wisata merupakan suatu wilayah geografis yang memiliki ciri khas tersendiri sehingga menarik untuk dikunjungi dan ditempati dalam jangka waktu sementara [1]. Salah satu destinasi yang populer karena pesona keindahan alamnya adalah pantai. Namun, terdapat risiko tersembunyi yang dapat mengancam keselamatan pengunjung, seperti fenomena *rip current* yang sering kali tidak disadari [2], [3]. Dilansir dari Pusat Meteorologi Maritim Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), *rip current* adalah arus kuat dari air laut yang bergerak menjauh dari pantai [4]. *Rip current* disebabkan oleh adanya pertemuan ombak yang sejajar dengan garis pantai sehingga menyebabkan terjadinya arus balik dengan kecepatan arus yang tinggi [5], [6], [7].

Rip current terdiri dari beberapa bagian arus, yaitu arus pengisi, leher arus, dan kepala arus. Arus ini sangat berbahaya karena kecepatannya mencapai lebih dari 0,8 m/s dengan lebar rata-rata 11 m, serta sering kali tidak tampak secara kasat mata [8], [9]. *Rip current* dikenal sebagai salah satu ancaman serius yang dapat mengakibatkan kecelakaan fatal dan dikategorikan sebagai *structural boundary-controlled* yang diprediksi terjadi secara permanen. Namun, teknologi pemantauan otomatis untuk mendeteksi keberadaan *rip current* masih terbatas [10].

Beberapa penelitian terdahulu telah mengembangkan deteksi *rip current* menggunakan pendekatan *deep learning*. RipVIS mengusulkan metode segmentasi berbasis analisis pola aliran air pada video pengawasan pantai [11], sedangkan RipFinder membangun deteksi *rip current* melalui perangkat mobile untuk mendukung respon cepat di lapangan [12]. Penelitian oleh Khan et al. membangun RipScout yang memanfaatkan drone untuk akuisisi citra udara dan menerapkan model *lightweight* untuk pemantauan area pesisir berskala luas [13]. Selain itu, standar evaluasi segmentasi *rip current* mulai dikembangkan secara luas melalui publikasi *AIM 2025 RipSeg Challenge Report* [14]. Namun, sebagian besar penelitian tersebut menggunakan dataset berukuran besar dan berfokus pada segmentasi serta inferensi *real-time*.

Salah satu pengembangan metode yang populer dan banyak digunakan untuk deteksi objek adalah *You Only Look Once* (YOLO), sebuah algoritma berbasis *deep learning* yang mampu melakukan identifikasi objek dalam citra atau video secara *real-time* dengan tingkat akurasi yang tinggi [15], [16]. YOLO bekerja dengan menggunakan *Convolutional Neural Network* (CNN) yang memungkinkan proses deteksi berlangsung cepat dan efisien dalam satu tahap pemrosesan (*one-stage detector*) [17], [18]. Algoritma ini dikembangkan oleh tim Ultralytics dan telah berevolusi dari YOLOv3 hingga YOLOv11 dengan tingkat ketepatan deteksi yang tinggi dan dievaluasi melalui metrik *precision*, *recall*, *mean Average Precision* (mAP) yang disebut sebagai indikator akurasi sistem. Versi terbaru yaitu YOLOv11 yang mengintegrasikan arsitektur *backbone* dan modul efisien seperti C3k2, SPPF (*Spatial Pyramid Pooling Fusion*), dan C2PSA (*Channel to Pixel Space Attention*) untuk meningkatkan representasi fitur [18], [19].

YOLOv11 menunjukkan peningkatan signifikan dalam nilai *mean Average Precision* (mAP) dan performa inferensi dibandingkan dengan versi sebelumnya [20]. Dapat dilihat pada YOLOv5 dan YOLOv8 yang masih mengandalkan modul C3 dan SPPF konvensional, sementara YOLOv11 telah menggunakan C3k2 dan C2PSA yang lebih efisien dalam ekstraksi fitur spasial. Hal ini yang menempatkan YOLOv11 sebagai model dengan *trade-off* kecepatan dan akurasi terbaik pada skenario *real-time* maupun dataset terbatas [21]. Selain itu, YOLOv11 telah berhasil diterapkan pada berbagai domain *remote sensing*, seperti deteksi drone berbasis citra udara dengan *Linear Attention Mechanism* yang ringan [22]. Pada penelitian terbaru, seperti YOLO11-FSDAT yang berfokus pada deteksi objek skala kecil dan penelitian YOLO-PSF mengoptimalkan ekstraksi fitur spasial untuk meningkatkan inferensi [23], [24]. Namun, meskipun YOLOv11 memiliki banyak keunggulan, performa modelnya tetap dipengaruhi oleh kualitas dan jumlah data latih.


Permasalahan yang dihadapi adalah kecilnya jumlah dataset yang menimbulkan masalah *overfitting* dan menurunkan akurasi deteksi. Salah satu pendekatan yang digunakan untuk mengatasi keterbatasan jumlah data latih adalah augmentasi data. Augmentasi data adalah teknik yang meningkatkan ukuran dan keragaman dataset dengan menghasilkan variasi baru dari data latih [25], [26], [27]. Teknik tersebut umum digunakan untuk mencegah *overfitting* dan meningkatkan kinerja model pada dataset berukuran kecil [28]. Pemilihan parameter augmentasi yang tepat sangat penting untuk meningkatkan generalisasi pada dataset terbatas. Beberapa teknik augmentasi memang meningkatkan akurasi pada skenario *few-shot detection*, tetapi sering kali disertai konsumsi energi yang tinggi (*performance-efficiency trade-off*) [29]. Efektivitas augmentasi ditentukan oleh kesesuaian strategi terhadap karakteristik dataset daripada sekadar jumlah variasi yang dihasilkan [30].

Oleh karena itu, penelitian ini bertujuan untuk mengoptimalkan parameter augmentasi data pada YOLOv11 dan menghasilkan model dengan nilai mAP yang lebih tinggi serta dapat mendeteksi *rip current* meskipun dilatih dengan dataset berukuran kecil. Model terbaik yang diperoleh akan diintegrasikan ke dalam sistem deteksi *rip current* berbasis web agar dapat diakses secara *real-time* oleh pengguna. Dengan demikian, kontribusi utama dari penelitian ini adalah (1) menerapkan YOLOv11 sebagai algoritma deteksi untuk deteksi *rip current*; (2) mengoptimalkan parameter augmentasi data

untuk meningkatkan variasi data latih; (3) menganalisis dampak augmentasi data terhadap performa YOLOv11 dalam hal nilai mAP dan kinerja model dalam mendeteksi; (4) menghasilkan model deteksi *rip current* yang lebih akurat sebagai dasar pengembangan sistem deteksi *rip current* di pantai.

2. METODE PENELITIAN

Metode penelitian ini terdiri dari 6 tahapan penelitian, yaitu *data acquisition* (akuisisi data), *data preprocessing*, *data augmentation*, *data splitting*, *training datasets*, *model evaluation*, dan *system implementation*. Tahapan tersebut diilustrasikan dengan diagram alur pada Gambar 1 sebagai berikut.



Gambar 1. Diagram Alur Tahapan Penelitian

Gambar 1 menunjukkan bahwa penelitian dimulai dengan akuisisi data citra *rip current*. Setelah itu, dilakukan *data preprocessing*, meliputi penanganan data mentah, anotasi dan *labelling*, serta perubahan ukuran citra. Selanjutnya, data dilakukan proses augmentasi berupa *crop*, rotasi, *brightness*, dan *blur* untuk menambah variasi citra. Data yang telah diproses kemudian dibagi menjadi data latih dan data validasi yang dijelaskan.

Hasil *data splitting* digunakan pada proses training menggunakan YOLOv11. Kemudian, hasil dari proses *training* dievaluasi menggunakan metrik *precision*, *recall*, dan *mean Average Precision* (mAP) untuk mengetahui performa model. Setelah diperoleh model terbaik, tahap terakhir adalah implementasi ke dalam sistem deteksi *rip current* berbasis web yang memungkinkan pengguna melakukan analisis citra maupun video pantai.

2.1. Data Acquisition (Akuisisi Data)

Tahap akuisisi data dilakukan menggunakan perangkat Google Earth Pro dengan memanfaatkan data historis perekaman citra satelit yang tersedia dari tahun 2010-2024 di sepanjang pesisir Depok-Parangtritis. Lokasi ini dipilih karena salah satu pesisir yang cukup sering mengalami kejadian kecelakaan laut akibat adanya *rip current*. Kecelakaan laut di Pantai Depok-Parangtritis tercatat sebanyak 607 kejadian dengan 238 korban sejak kurun 1991-2016, di mana 473 diantaranya terjadi pada rentang 2009-2015, dan jumlah korban meninggal atau hilang sebanyak 35 jiwa [31], [32]. Muntasib et al. (2018) menggolongkan bahaya *rip current* di wilayah ini sebagai bahaya bencana yang dapat menimbulkan risiko yang penting (*substantial risk*) [33].


Penambahan data dilakukan dengan memanfaatkan data foto udara pesisir Depok-Parangtritis yang diakuisisi oleh Balai Geospasial Pesisir dan Gumuk Pasir (BGPGP), Badan Informasi Geospasial (BIG) pada tahun 2019-2020. Seluruh data citra yang terpilih selanjutnya dilakukan proses *georeferencing* untuk menetapkan posisi koordinat geografis dari wilayah kajian dan dilakukan *layouting* pada skala detil agar kenampakan arus pantai tampak jelas. Secara keseluruhan, diperoleh 157 citra yang memenuhi kriteria kelayakan. Penelitian ini hanya menggunakan citra satelit dan foto udara publik yang tidak menampilkan identitas individu, sehingga sepenuhnya menjaga prinsip anonimitas.

2.2. Data Preprocessing

Tahap *data preprocessing* sangat penting dilakukan dalam proses *training* model deteksi objek. Tahap ini merujuk pada proses perubahan data mentah menjadi data yang berkualitas tinggi dan mempersiapkan sebelum digunakan dalam proses *training* [34], [35]. *Preprocessing* bertujuan untuk memastikan kesesuaian data sebagai masukan untuk model dan meningkatkan kualitas hasil analisis [36]. Dalam penelitian ini, ada beberapa langkah yang dilakukan untuk mendapatkan dataset yang berkualitas.


Pertama, penanganan data mentah yang diperoleh dari proses akuisisi data. Data mentah ini perlu diproses lebih lanjut agar area garis pantai dan ombak dapat terlihat lebih jelas. Oleh karena itu, diterapkan teknik *crop* untuk memotong bagian citra yang tidak diperlukan dan menghasilkan citra baru dengan area pantai yang lebih jelas. Proses *crop* bertujuan untuk menyederhanakan citra, mengurangi latar belakang yang tidak relevan, serta memudahkan tahap anotasi selanjutnya.

Kedua, melakukan proses anotasi dan *labelling* melalui platform Roboflow. Setelah semua citra diunggah ke platform tersebut, langkah selanjutnya adalah membuat kotak pembatas (*bounding box*) secara manual dan memberikan nama pada label kategori yang sesuai misalnya RIP. Proses anotasi ini bertujuan untuk memberikan informasi lokasi *rip current* pada setiap citra melalui *bounding box*. Proses tersebut diilustrasikan pada Gambar 2 sebagai berikut.



Gambar 2. Proses Anotasi dan Labeling

Ketiga, melakukan pengaturan orientasi gambar secara otomatis (*Auto-Orient*) untuk memastikan posisi citra konsisten [34]. Langkah ini penting agar model tidak salah mengenali pola arus karena adanya variasi orientasi data. Terakhir, setiap citra di *resize* ke ukuran standar YOLO yaitu 640 x 640 piksel tanpa mempertahankan rasio aspek yang asli. Hal ini menghasilkan citra yang seragam di seluruh dataset sehingga memudahkan model dalam membaca pola visual dengan ukuran piksel yang konsisten. Proses *resize* juga berfungsi mengurangi beban komputasi, karena model tidak lagi menerima citra dengan ukuran bervariasi yang berpotensi memperlambat proses *training*. Proses pengaturan tersebut diilustrasikan pada Gambar 3 sebagai berikut.




Gambar 3. Proses Auto-Orient dan Resize

2.3. Data Augmentation

Augmentasi data merupakan teknik yang digunakan untuk menambah variasi data *training* dengan memodifikasi data asli tanpa mengubah nama label objek. Penerapan teknik ini memungkinkan model belajar dari berbagai variasi citra untuk meningkatkan akurasi [36]. Beberapa penelitian sebelumnya telah menjelaskan bahwa augmentasi data sangat penting dalam penelitian yang menggunakan citra dengan dataset kecil, karena dapat membantu meningkatkan variasi data, mengurangi *overfitting*, dan meningkatkan kinerja model [37], [38]. Ada empat teknik data augmentasi yang digunakan dalam penelitian ini, yaitu *crop*, rotasi, *brightness*, dan *blur*.

Teknik *crop* diterapkan dengan memangkas sebagian area citra sehingga objek target dapat muncul pada posisi yang berbeda [18]. Pada penelitian ini, pemangkasan dilakukan dengan skala 0-10% dari ukuran citra asli. Rotasi digunakan untuk memutar citra dalam sudut tertentu sehingga menghasilkan variasi orientasi objek [39]. Rotasi pada penelitian ini dibatasi pada sudut -10° hingga $+10^{\circ}$ agar tetap realistis dengan kondisi gambar dipantai. Penyesuaian *brightness* dilakukan dengan mengubah tingkat kecerahan citra secara keseluruhan untuk meniru perbedaan kondisi cahaya [39]. Dalam penelitian ini, variasi *brightness* di antara -10% hingga $+10\%$. Efek *blur* digunakan untuk menghasilkan citra yang sedikit kabur, misalnya akibat goyangan kamera atau keterbatasan kualitas sensor [18]. *Blur* diterapkan dalam penelitian ini menggunakan *kernel* 1 piksel. Tahap augmentasi dilakukan pada platform Roboflow dan diilustrasikan pada Gambar 4 sebagai berikut.



Gambar 4. Proses Augmentasi


2.4. Data Splitting

Proses *data splitting* atau dapat disebut juga pembagian data merupakan langkah penting dalam eksperimen *machine learning* agar model dapat dilatih, divalidasi, dan di uji secara adil. Dataset umumnya dibagi menjadi tiga *subset*, yaitu *training set*, *validation set*, dan *test set* [30]. *Training set* digunakan untuk melatih parameter model, *validation set* berfungsi untuk menilai performa model pada data yang tidak dilatih sekaligus membantu dalam proses *tuning hyperparameter*, sedangkan *test set* digunakan untuk mengukur kinerja model pada data baru [26].

Dalam penelitian ini, dataset dibagi menjadi dua *subset*, yaitu *training* dan *validation* dengan perbandingan 70:30. Pemisahan ini dilakukan secara acak agar distribusi data tetap representatif dan memastikan evaluasi model lebih objektif [7]. Penggunaan dua *subset* (*training* dan *validation*) dipilih karena jumlah dataset yang terbatas. Dengan kondisi ini, pemisahan ke dalam tiga *subset* berisiko mengurangi jumlah data latih secara signifikan sehingga menurunkan performa model. Oleh karena itu, penelitian ini tidak menggunakan *test set* terpisah, melainkan memanfaatkan *validation set* sebagai dasar evaluasi kinerja model. Pembagian dataset dilakukan setelah proses augmentasi untuk memastikan variasi data dapat terdistribusi secara merata di setiap *subset*.

2.5. Training Dataset

Pada tahap ini, dataset yang telah melalui proses *preprocessing*, augmentasi, dan *split data* akan dilatih menggunakan algoritma YOLOv11. YOLOv11 termasuk dalam kategori *one-stage object detector* yang mampu melakukan deteksi objek secara *real-time* dengan keseimbangan antara kecepatan inferensi dan ketepatan deteksi [10], [40]. Algoritma ini memiliki tiga komponen utama, yaitu *backbone* untuk ekstraksi fitur, *neck* yang menggabungkan informasi multiskala, dan *head* yang melakukan prediksi *bounding box* dan klasifikasi objek [11]. Selain itu, YOLOv11 dilengkapi dengan modul efisien seperti C3k2, SPPF (*Spatial Pyramid Pooling Fusion*), dan C2PSA (*Channel to Pixel Space Attention*) yang berfungsi meningkatkan representasi fitur sehingga performa deteksi lebih baik pada objek kecil maupun kondisi kompleks [18], [19], [40]. Arsitektur umum YOLOv11 dapat dilihat pada Gambar 5 berikut.



Gambar 5. Arsitektur umum YOLOv11

Dalam penelitian ini, proses pelatihan dilakukan menggunakan parameter utama sebagai berikut. jumlah *epoch* sebanyak 200, ukuran *batch size* sebesar 16, serta resolusi citra 640 x 640 piksel. Model *pre-train* yang digunakan penelitian ini adalah YOLO11s.pt. Optimizer yang digunakan otomatis dari *framework* Ultralytics, yaitu AdamW dengan nilai *learning rate* 0,002 dan *momentum* 0,9. Penggunaan AdamW memberikan stabilitas yang lebih baik pada proses pembaruan bobot dibandingkan SGD tradisional, karena mampu mengontrol regulasi melalui *weight decay* [25]. Tujuan dari tahap *training* ini adalah menghasilkan model YOLOv11 yang mampu mendeteksi *rip current* secara konsisten dengan performa yang optimal meskipun jumlah dataset terbatas. Model terbaik ditentukan berdasarkan hasil evaluasi pada *subset validation*.

2.6. Model Evaluation (Evaluasi Model)

Tahap evaluasi model bertujuan untuk mengukur kinerja YOLOv11 dalam mendeteksi *rip current* pada citra pantai. Evaluasi model dilakukan pada *validation data* yang tidak dilibatkan dalam proses *training*, penelitian ini menggunakan beberapa metrik seperti *precision*, *recall*, dan *mean Average*

Precision (mAP) yang umum digunakan dalam penelitian deteksi objek. *Precision* mengacu pada kemampuan model hanya untuk mengenali objek yang relevan dan sejauh mana model dapat meminimalkan kesalahan deteksi palsu [17], [41]. Nilai yang dihitung oleh *precision* adalah *True Positive* (TP) ketika model dengan benar memprediksi kelas yang telah dibuat dan *False Positive* (FP) ketika model salah memprediksi objek kelas yang dibuat [17], [34]. Rumus *precision* ditunjukkan pada persamaan (1).

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

Recall atau sensitivitas digunakan untuk mengukur sejauh mana model dapat menemukan seluruh objek target dalam dataset. Nilai yang dihitung oleh *recall* yaitu *True Positive* (TP) dari semua nilai *precision* yang tersedia (*ground truth*) dan *False Negative* (FN) yang berarti model gagal memprediksi kelas yang dibuat ketika sebenarnya ada [17], [41]. Nilai *recall* yang tinggi menunjukkan tingkat *False Negative* (FN) yang rendah sehingga memungkinkan model untuk menangkap semua target secara komprehensif [16], [18]. Rumus *recall* ditunjukkan pada persamaan (2).

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

Mean Average Precision (mAP) adalah metrik komprehensif yang menilai keseimbangan antara *precision* dan *recall* [17]. Perhitungan mAP diperoleh dari *Average Precision* (AP), yaitu area dibawah kurva *precision-recall* untuk setiap kelas, yang kemudian di rata-rata di semua kelas objek yang dibuat berdasarkan nilai ambang batas tertentu [18], [34], [41]. Varian yang umum digunakan adalah mAP₅₀, yaitu nilai AP pada ambang *Intersection over Union* (IoU) sebesar 0,5 [18], [40]. Nilai mAP yang tinggi menunjukkan bahwa model memiliki performa deteksi yang baik [42]. Rumus mAP ditunjukkan pada persamaan (3).

$$mAP_{50} = \frac{1}{N} \sum_{i=1}^N AP_{50,i} \quad (3)$$


2.7. System Implementation

Tahap implementasi dilakukan dengan mengintegrasikan model YOLOv11 terbaik dari hasil *training* dan evaluasi ke dalam sistem deteksi *rip current* berbasis website. Pemilihan model terbaik berdasarkan hasil evaluasi pada data validasi dengan mempertimbangkan nilai *mean Average Precision* (mAP) tertinggi serta keseimbangan antara *precision* dan *recall*. Integrasi model deep learning ke dalam aplikasi web umumnya dilakukan dengan menggunakan *framework* Flask sebagai *backend* yang memuat model YOLOv11 yang telah di *training* (file best.pt) dan mengatur alur prediksi. Antarmuka pengguna dibangun menggunakan kombinasi HTML, CSS, dan JavaScript sehingga pengguna dapat mengunggah citra atau video pantai untuk dianalisis [43]. Hasil deteksi ditampilkan secara interaktif dalam bentuk *bounding box* pada citra atau video yang diunggah, disertai label kelas RIP dan nilai *confidence score*. Implementasi model kecerdasan buatan ke dalam aplikasi web terbukti mampu meningkatkan keterjangkauan sistem dan mempermudah pengguna dalam memanfaatkan teknologi secara langsung [44].

3. HASIL

3.1. Data Acquisition (Akuisisi Data)

Tahap akuisisi data menghasilkan total 157 citra pesisir Depok-Parangtritis. Sebanyak 122 citra diperoleh dari Google Earth Pro dengan memanfaatkan data historis citra satelit periode 2010-2014, seperti yang ditunjukkan pada Gambar 6 berikut.



Gambar 6. Data Citra Google Earth Pro

Selain itu, terdapat 35 citra tambahan diperoleh dari hasil foto udara yang diakuisisi oleh Balai Geospasial Pesisir dan Gumuk Pasir (BGPGP), Badan Informasi Geospasial (BIG) pada tahun 2019-2020, seperti yang ditampilkan pada Gambar 7 berikut.



Gambar 7. Data Citra Foto Udara

Pada data foto udara, beberapa citra memiliki cakupan area yang luas sehingga mencakup bagian darat dan laut sekaligus. Oleh karena itu, diperlukan tahap *preprocessing* untuk menyesuaikan format dan memperjelas area garis pantai serta pola ombak yang menjadi fokus deteksi.

3.2. Data Preprocessing

Data yang di peroleh dari proses akuisisi selanjutnya melalui tahap preprocessing untuk memastikan kualitas dan konsistensi sebelum digunakan dalam pelatihan model. Tahapan ini mencakup pemotongan (*cropping*), anotasi dan *labelling*, pengaturan orientasi citra, serta *resize* agar seluruh data memiliki ukuran seragam dan area objek *rip current* terlihat jelas.


Tahap pertama dilakukan pada citra hasil foto udara yang memiliki cakupan area yang luas. Citra tersebut dipotong menggunakan teknik *crop* untuk memfokuskan pada area garis pantai dan pola ombak yang menjadi objek utama *rip current*. Proses ini membantu menghilangkan citra yang tidak relevan, seperti daratan disekitar pantai. Hasil *crop* memberikan area pengamatan yang lebih spesifik sehingga pola *rip current* dapat diamati dengan lebih mudah. Salah satu contoh hasil *crop* dapat dilihat pada Gambar 8 berikut.



Gambar 8. Citra Hasil Proses Crop

Selanjutnya, dilakukan tahap anotasi dan *labelling* untuk menandai area *rip current* dengan *bounding box* dan label kategori “RIP” menggunakan platform Roboflow. Setelah seluruh citra diberi label, dilakukan pengaturan orientasi otomatis (*Auto-Orient*) untuk menjaga keseragaman arah citra terhadap garis pantai. Kemudian, dilakukan *resize* dengan ukuran 640 x 640 piksel sesuai dengan standar input YOLO. Penyesuaian ini tidak hanya meningkatkan konsistensi dataset, tetapi juga memastikan bahwa setiap citra dapat diproses dengan efisien selama tahap pelatihan.

Dengan ukuran input yang seragam, model lebih mudah mempelajari fitur visual yang relevan tanpa dipengaruhi perbedaan skala atau resolusi antar citra. Proses anotasi dan preprocessing ini berfungsi sebagai upaya awal untuk meminimalkan *noise* dan variabilitas yang tidak diperlukan, sehingga dataset menjadi lebih representatif terhadap kondisi nyata. Hasil dari keseluruhan tahapan *preprocessing* ditampilkan pada Gambar 9 yang memperlihatkan citra pantai beserta *bounding box* area *rip current* yang telah diberi label dengan jelas.



Gambar 9. Citra Hasil Preprocessing

3.3. Data Augmentation

Tahap augmentasi data dilakukan untuk meningkatkan jumlah citra dan variasi visual dataset melalui teknik *crop*, rotasi, *brightness*, dan *blur*. Dengan teknik ini, dataset menjadi lebih beragam dari segi orientasi garis pantai, intensitas pencahayaan, serta ketajaman pola ombak. Variasi tambahan tersebut diharapkan mampu meningkatkan kinerja model YOLOv11 dalam mendeteksi *rip current* pada

berbagai kondisi visual citra. Salah satu contoh perbandingan antara citra tanpa augmentasi (*original*) dan citra hasil augmentasi ditunjukkan pada Gambar 10 sebagai berikut.



Gambar 10. (a) citra tanpa augmentasi atau original; (b) citra dengan augmentasi

Proses augmentasi menghasilkan citra baru yang secara visual menunjukkan variasi signifikan dibandingkan citra asli. Misalnya, pada Gambar 10 terlihat bahwa citra hasil augmentasi (b) memiliki sudut pandang yang sedikit berbeda dan tingkat pencahayaan yang lebih terang dari citra tanpa augmentasi (a). Variasi ini memperluas konteks pembelajaran model sehingga YOLOv11 tidak hanya bergantung pada pola tertentu, tetapi juga dapat mendeteksi rip current secara lebih adaptif pada kondisi lingkungan yang beragam.

3.4. Dataset

Dataset yang digunakan dalam penelitian ini merupakan hasil akhir dari tahapan akuisisi, *preprocessing*, dan augmentasi data citra pesisir Depok-Parangtritis. Seluruh citra telah melalui proses anotasi, pengaturan orientasi otomatis, serta *resize* menggunakan platform Roboflow. Hasil dari proses tersebut, penelitian ini mendapatkan tiga dataset dengan jumlah data dan sumber data yang berbeda, seperti yang ditunjukkan pada Tabel 1 sebagai berikut.

Tabel 1. Hasil Dataset

Name of Dataset	Data Source	Number of Data	Augmentation (Yes/No)	Number of Data After Augmentation
Dataset 1	Google Earth	122	No	122
			Yes	234
Dataset 2	Aerial Photographs	35	No	35
			Yes	105
Dataset 3	Google Earth + Aerial Photographs	157	No	157
		(122 + 35)	Yes	377

Berdasarkan Tabel 1, ketiga dataset tersebut digunakan untuk mengevaluasi konsistensi dan kemampuan generalisasi model YOLOv11 terhadap variasi sumber data. Dataset 1 dan 2 mewakili karakteristik visual citra satelit yang berbeda dari Google Earth dan foto udara. Sementara, Dataset 3 digunakan untuk menganalisis pengaruh penggabungan kedua sumber terhadap peningkatan performa deteksi.

Pendekatan ini memberikan dasar untuk membandingkan performa model dalam mempertahankan akurasi serta kemampuannya beradaptasi terhadap kondisi citra pantai yang bervariasi. Setiap dataset memiliki dua versi, yaitu tanpa augmentasi (*original*) dan dengan augmentasi. Hal ini bertujuan agar dataset dapat diuji efektivitas teknik augmentasi dalam meningkatkan nilai mAP dan menekan risiko overfitting pada jumlah data yang terbatas.

3.5. Data Splitting

Tahap *data splitting* dilakukan setelah proses augmentasi untuk membagi dataset menjadi dua subset, yaitu *training* dan *validation*. Perbandingan yang digunakan adalah 70% untuk training set dan 30% untuk validation set. Pembagian ini dilakukan secara acak dengan tujuan untuk memastikan distribusi data yang seimbang serta menjaga keragaman citra pada setiap *subset*, sehingga proses pelatihan model tidak bias terhadap salah satu sumber. Penelitian ini memiliki beberapa eksperimen dengan penggabungan dua dataset untuk tahap training. Rincian pembagian data dari setiap eksperimen ditunjukkan pada Tabel 2.

Tabel 2. Hasil Data Splitting

Name of Dataset	Number of Data		Augmentation (Yes/No)
	Data Train (70%)	Data Valid (30%)	
Dataset 1	86	36	No
	164	70	Yes
Dataset 1 Original + Dataset 3 Augmentation	350	149	-
Dataset 2	25	10	No
	74	31	Yes
Dataset 2 Original + Dataset 3 Augmentation	289	123	-
Dataset 3	110	47	No
	264	113	Yes


Berdasarkan Tabel 2, Dataset 1 dan Dataset 2 dibagi secara langsung baik pada versi original maupun hasil augmentasi. Sementara itu, pada Dataset 3 yang merupakan gabungan antara Dataset 1 dan Dataset 2, pembagian data dilakukan setelah proses penggabungan. Secara proporsional, *subset training* mencakup 81 citra Dataset 1 dan 29 citra Dataset 2, sedangkan *subset validation* terdiri atas 41 citra Dataset 1 dan 6 citra Dataset 2.

Pada variasi gabungan Dataset 1 original dan Dataset 3 augmentasi dengan jumlah data 499 citra. *Subset training* terdiri dari 88 citra Dataset 1 original dan 262 citra Dataset 3 augmentasi, serta 34 citra Dataset 1 original dan 115 citra Dataset 3 augmentasi untuk *subset validation*. Selain itu, gabungan Dataset 2 original dan Dataset 3 augmentasi yang berjumlah 412 citra, mendapatkan 24 citra Dataset 2 original dan 265 citra Dataset 3 augmentasi untuk subset training. Subset validation nya terdiri dari 11 citra Dataset 2 original dan 112 citra Dataset 3 augmentasi.

3.6. Training Datasets


Proses *training* dilakukan menggunakan model Yolo11s.pt selama 200 *epoch* dengan ukuran citra 640 x 640 piksel. Pembagian dataset mengikuti proporsi 70% *data training* dan 30% *data validation*, sebagaimana dijelaskan pada subbab sebelumnya. Tujuan training ini adalah menghasilkan model YOLOv11 yang mampu mengenali pola *rip current* secara konsisten meskipun jumlah dataset terbatas. Model terbaik ditentukan berdasarkan hasil evaluasi tertinggi pada *subset validation* dan disimpan dengan format .pt sehingga siap diimplementasikan ke sistem. Selama proses *training*, model

YOLOv11 menunjukkan variasi performa yang cukup kontras antar dataset. Hasil *training* divisualisasikan menggunakan grafik *loss* dan metrik evaluasi seperti pada Gambar 11 dan Gambar 12 berikut.



Gambar 11. Grafik Hasil Training Dataset 2 Tanpa Augmentasi

Gambar 11 menampilkan hasil *training* dengan performa terendah dari Dataset 2 tanpa augmentasi. Terlihat bahwa kurva *loss* pada *data training* maupun *validation* mengalami ketidakstabilan dan cenderung fluktuatif dengan metrik evaluasi yang stagnan pada level rendah. Hal ini menunjukkan bahwa jumlah data yang terbatas membuat model sulit mencapai konvergensi yang stabil. Berikutnya, Gambar 12 menunjukkan grafik pada dataset dengan hasil terbaik. Visualisasi ini membantu untuk memahami perbedaan konvergensi model serta stabilitas performa antar dataset.



Gambar 12. Grafik Hasil Training Dataset 1 Original dan Dataset 3 Augmentasi

Gambar 12 menunjukkan hasil *training* dengan performa terbaik yaitu gabungan dari Dataset 1 original dengan Dataset 3 Augmentasi. Kurva *loss* pada *data training* dan *validation* menurun secara konsisten, sementara metrik evaluasi mengalami peningkatan yang stabil hingga mendekati nilai konvergensi. Perbedaan ini menegaskan bahwa augmentasi data memberikan kontribusi signifikan terhadap kemampuan generalisasi model dalam mengenali pola *rip current* pada kondisi pantai yang bervariasi secara optimal dan menghasilkan performa deteksi yang lebih baik.

3.7. Model Evaluation (Evaluasi Model)

Evaluasi model dilakukan untuk mengukur performa hasil training YOLOv11 menggunakan metrik *precision*, *recall*, dan *mean Average Precision* (mAP). Hasil evaluasi model ditunjukkan pada Tabel 3 sebagai berikut.


Tabel 3. Hasil Evaluasi Model

Name of Dataset	Augmentation (Yes/No)	Precision	Recall	mAP50
Dataset 1	No	46.3%	44%	40.3%
	Yes	83.4%	70.7%	78.1%
Dataset 1 Original + Dataset 3 Augmentation	-	90.6%	85.7%	90.4%
Dataset 2	No	31.8%	32.8%	23.8%
	Yes	92.5%	78.5%	86.5%
Dataset 2 Original + Dataset 3 Augmentation	-	86.1%	77.2%	82.8%
Dataset 3	No	47%	33.6%	31.6%
	Yes	84%	71.7%	77.8%

Berdasarkan hasil pada Tabel 3, terlihat bahwa penggunaan augmentasi data secara konsisten meningkatkan performa model pada seluruh dataset. Dataset tanpa augmentasi dengan jumlah data terbatas cenderung menghasilkan nilai evaluasi yang relatif rendah. Hasil paling rendah ditunjukkan pada Dataset 2 tanpa augmentasi dengan nilai *precision* 31,8%, *recall* 32,8%, dan mAP50 23,8%. Hal ini memperlihatkan bahwa keterbatasan jumlah citra membuat model sulit mengenali pola *rip current* secara stabil. Setelah dilakukan augmentasi, performa model meningkat signifikan pada semua dataset. Sebagai contoh, pada Dataset 1 nilai mAP50 meningkat dari 40,3% menjadi 78,1%.

Selain itu, Dataset 2 naik dari 23,8% menjadi 86,5%. Peningkatan ini menunjukkan bahwa penambahan variasi citra melalui augmentasi membantu model mempelajari pola *rip current* dalam kondisi yang lebih beragam. Hasil terbaik dan tertinggi secara keseluruhan diperoleh pada dataset gabungan antara Dataset 1 original dan Dataset 3 augmentasi dengan nilai *precision* 90,6%, *recall* 85,7%, dan mAP50 90,4%. Kombinasi ini memberikan keseimbangan antara jumlah data yang besar dan variasi visual yang tinggi, sehingga model mampu mencapai performa deteksi yang lebih optimal dibandingkan eksperimen lainnya.


Performa model divisualisasikan menggunakan kurva *Precision-Recall* (PR) yang merupakan grafik hubungan antara *precision* dan *recall* pada berbagai nilai ambang kepercayaan (*confidence threshold*). Grafik ini penting untuk mengevaluasi keseimbangan antara ketepatan deteksi dan kelengkapan deteksi. Semakin luas area di bawah kurva, semakin baik performa model dalam mendeteksi objek secara konsisten. Visualisasi kurva PR ditunjukkan pada Gambar 13 dan Gambar 14 berikut.



Gambar 13. Kurva PR Dataset 2 Tanpa Augmentasi

Pada Gambar 13 ditampilkan kurva PR dari eksperimen dengan hasil terendah yaitu Dataset 2 tanpa augmentasi. Kurva terlihat mendatar dan area di bawah kurva sempit dengan nilai mAP50 hanya

0,238. *Precision* maksimum tercatat sebesar 1.00 namun hal itu terjadi ketika *recall* mendekati 0, sedangkan *recall* maksimum tidak diikuti oleh *precision* yang stabil. Kondisi ini menandakan bahwa model cenderung *overfitting* pada sebagian kecil data dan gagal mempertahankan keseimbangan deteksi pada seluruh rentang *threshold*. Dengan demikian, meskipun sesekali model menghasilkan deteksi yang tepat, tetapi secara keseluruhan performanya tidak mampu mendeteksi *rip current* secara konsisten. Berikutnya, Gambar 14 menunjukkan kurva PR pada dataset dengan hasil terbaik.




Gambar 14. Kurva PR Dataset 1 Original dan Dataset 3 Augmentasi

Gambar 14 memperlihatkan kurva PR dari eksperimen dengan hasil terbaik yaitu gabungan Dataset 1 original dan Dataset 3 augmentasi. Kurva berada dekat dengan sudut kanan atas dengan area di bawah kurva yang luas dengan nilai mAP50 mencapai 0,904. *Precision* dan *recall* keduanya mendekati 1.00 pada sebagian besar *threshold confidence*, menandakan model tidak hanya akurat tetapi juga konsisten dalam mendeteksi *rip current*. Stabilitas kurva ini menunjukkan bahwa model mampu menjaga keseimbangan antara ketepatan dan kelengkapan deteksi, sehingga performa deteksi menjadi lebih andal untuk kondisi nyata di pantai. Hal ini selaras dengan nilai *precision* dan *recall* yang tinggi pada Tabel 3, serta membuktikan bahwa augmentasi dan penggabungan dataset memberikan kontribusi signifikan terhadap kemampuan generalisasi model.

3.8. System Implementation


Model YOLOv11 terbaik hasil training dan evaluasi diintegrasikan ke dalam sistem deteksi *rip current* berbasis website. Implementasi dilakukan menggunakan *framework* Flask sebagai *backend* untuk memuat file model terlatih (best.pt) dan menjalankan proses prediksi. Antarmuka sistem yang digunakan pengguna dibangun dengan HTML, CSS, dan JavaScript untuk mengunggah citra maupun video pantai yang akan dianalisis. Hasil implementasi sistem ditunjukkan pada Gambar 15 berikut.



Gambar 15. Halaman Beranda


Tampilan awal sistem ini, menyajikan informasi singkat mengenai *rip current* beserta ilustrasi visual untuk menarik perhatian pengguna. Selain itu, halaman ini dilengkapi tombol navigasi yang berfungsi mengarahkan pengguna menuju halaman edukasi dan halaman deteksi. Pada tahap ini, desain antarmuka difokuskan untuk memberikan pengalaman pengguna yang sederhana dan informatif.

Elemen visual seperti ilustrasi *rip current* dan tombol “Learn More” membantu meningkatkan pemahaman pengguna mengenai bahaya *rip current* sebelum mencoba fitur deteksi otomatis. Dengan pendekatan ini, sistem tidak hanya berperan sebagai alat deteksi, tetapi juga sebagai media edukasi yang mendukung peningkatan kesadaran keselamatan di pantai. Berikutnya adalah halaman kedua dari sistem ini ditampilkan pada Gambar 16 sebagai berikut.



Gambar 16. Halaman Edukasi


Halaman edukasi menampilkan informasi dasar kepada pengguna mengenai fenomena *rip current*. Informasi yang disajikan akan sangat mendukung pemahaman pengguna mengenai definisi, ciri-ciri, serta langkah penyelamatan diri saat terjebak arus. Selain itu, terdapat tombol navigasi yang dapat langsung mengarahkan pengguna menuju halaman deteksi. Terakhir, hasil implementasi halaman deteksi ditunjukkan pada Gambar 17.



Gambar 17. Halaman Deteksi dan Hasil Deteksi menggunakan Gambar

Halaman deteksi menyediakan dua jenis input, yaitu gambar dan video yang dapat diunggah melalui file tersimpan, kamera atau salinan papan klip. Pengguna juga dapat menyesuaikan parameter deteksi, seperti ukuran gambar dan *confidence threshold* nya. *Confidence threshold* adalah batas minimal nilai keyakinan model yang ditentukan pengguna untuk menampilkan hasil deteksi. Setelah input diberikan, sistem secara otomatis menganalisis citra atau video dan menampilkan hasil dalam bentuk citra yang telah dianotasi menggunakan *bounding box* serta *confidence score*. Selain itu, sistem menyediakan fitur unduh agar pengguna dapat menyimpan hasil deteksi.

Gambar 17 menunjukkan tampilan halaman deteksi ketika pengguna mengunggah citra pantai. Proses deteksi dilakukan pada citra uji eksternal yang berasal dari sumber lain dan tidak termasuk dalam dataset sebelumnya [45]. Hasil deteksi memperlihatkan bahwa sistem mampu menandai area *rip current* dengan baik melalui *bounding box* dan *confidence score*. Untuk tampilan jenis input video ditampilkan pada Gambar 18.



Gambar 18. Halaman Deteksi menggunakan Video

Gambar 18 menunjukkan tampilan halaman deteksi menggunakan video. Sistem menyediakan fitur tambahan berupa pemotongan durasi menggunakan ikon gunting sebelum diproses. Hal ini memudahkan pengguna dalam memilih segmen video yang relevan untuk dianalisis. Hasil deteksi ditampilkan dalam bentuk video teranotasi dengan *bounding box* dan *confidence score*, sehingga pengguna dapat memantau area yang terdeteksi secara lebih interaktif.

4. DISKUSI

Penelitian sebelumnya telah menunjukkan efektivitas model YOLO dalam berbagai objek deteksi, termasuk pada bidang maritim dan pengawasan. Sebagai contoh, RipDet adalah sebuah varian Tiny-Yolov3 yang mengusulkan arsitektur ringan untuk deteksi *rip current* dan menggunakan teknik augmentasi data untuk membantu model beradaptasi dengan jumlah data yang terbatas. Hasil eksperimen RipDet mencapai 98,13% untuk mAP50 dengan tetap mempertahankan kecepatan inferensi yang tinggi [7]. Sementara itu, penelitian oleh Dimitriu et al. (2025) memperkenalkan RipVis dengan menekankan pentingnya keragaman dataset yang mencakup kondisi pantai yang berbeda, sehingga model mampu beradaptasi dengan lingkungan nyata dan hasil evaluasi yang meningkat seiring penambahan variasi data video [11]. Di luar domain *rip current*, YOLOv8 dioptimasi untuk pengawasan berbasis CCTV *real-time* yang berhasil mendeteksi wajah (*recall* 71,7%, *precision* 89,9%, mAP50 85,0%) dan orang (*recall* 92,4%, *precision* 92,9%, mAP50 96,0%) [41]. Hasil-hasil tersebut secara umum menegaskan bahwa keberagaman data dan pemilihan arsitektur model merupakan faktor penting dalam meningkatkan kinerja deteksi.

Dalam penelitian ini, YOLOv11 menunjukkan performa yang cukup baik dalam mendeteksi *rip current* setelah dilakukan augmentasi data. Model terbaik memperoleh nilai *precision* 90,6%, *recall* 85,7%, dan mAP50 90,4% yang jauh lebih tinggi dibandingkan dataset tanpa augmentasi. Teknik augmentasi berupa *crop*, rotasi, penyesuaian *brightness*, dan *blur* terbukti efektif memperkaya variasi visual dataset. Variasi ini menyerupai kondisi nyata di pantai, seperti perubahan intensitas cahaya, sudut pengambilan gambar, maupun efek blur pada rekaman, sehingga model mampu melakukan generalisasi yang lebih baik terhadap data uji eksternal. Hal ini sejalan dengan studi Interpretable Deep Learning Applied to Rip Current Detection and Localization yang menekankan pentingnya simulasi kondisi visual dalam meningkatkan adaptabilitas model, serta diperkuat dengan penelitian Explainable Rip Current

Detection and Visualization XAI EigenCAM yang menambah aspek interpretabilitas dalam sistem deteksi [6], [46].

Jika dibandingkan dengan penelitian lain, hasil ini searah dengan penelitian RipScout yang menggunakan drone untuk memperluas cakupan citra pantai [13]. Perbedaan pendekatan tersebut menegaskan bahwa pengayaan variasi data maupun pemilihan sumber data merupakan faktor yang sama pentingnya dalam meningkatkan performa deteksi rip current. Dari sisi informatika, integrasi YOLOv11 berbasis augmentasi ke dalam aplikasi web yang dikembangkan dalam penelitian ini menunjukkan nilai praktis sebagai sistem pemantauan real-time berbasis AI.

Meskipun demikian, penelitian ini masih memiliki keterbatasan berupa ukuran dataset yang kecil serta tidak adanya *test set* terpisah, sehingga evaluasi berpotensi bias. Untuk mengatasi hal ini, penelitian lanjutan dapat memanfaatkan teknik augmentasi lanjutan seperti penelitian *Anomaly-Focused Augmentation* atau integrasi dengan segmentasi untuk meningkatkan robustness pada edge computing maupun sistem real-time [14], [26].

5. KESIMPULAN

Penelitian ini berhasil mengimplementasikan YOLOv11 untuk deteksi rip current pada citra pantai dengan pendekatan augmentasi data. Hasil eksperimen menunjukkan bahwa augmentasi data berperan penting dalam meningkatkan performa model. Model terbaik diperoleh dari kombinasi dataset 1 original dan dataset 3 augmentasi dengan nilai *precision* 90,6%, *recall* 85,7%, dan mAP50 90,4%. Hasil ini menegaskan bahwa keragaman visual pada dataset sangat berpengaruh terhadap kemampuan generalisasi model.

Kontribusi penelitian ini meliputi penerapan YOLOv11 sebagai algoritma deteksi rip current, pembuktian efektivitas augmentasi data dalam meningkatkan kinerja model, serta integrasi model ke dalam aplikasi web untuk deteksi rip current secara otomatis pada citra maupun video pantai dengan tampilan hasil berupa *bounding box* dan *confidence score*. Implementasi ini dapat menjadi dasar bagi pengembangan sistem pemantauan pantai dan peringatan dini yang berorientasi pada keselamatan pengunjung pantai.

Sebagai tindak lanjut dari keterbatasan penelitian ini, disarankan tiga arah pengembangan. Pertama, menambah jumlah data dan memperluas variasi dataset agar evaluasi lebih robust. Kedua, menggabungkan metode deteksi dengan segmentasi untuk meningkatkan presisi area deteksi. Ketiga, mengeksplorasi teknik augmentasi canggih berbasis model difusi yang mampu menghasilkan variasi data sintesis. Alternatif lainnya adalah pemanfaatan model YOLO yang lebih ringan agar sistem dapat diterapkan secara efisien pada perangkat dengan keterbatasan komputasi.

REFERENSI

- [1] N. Kh. K. Et Al., "TOURIST DESTINATION AS AN OBJECT OF RESEARCH OF SOCIAL AND ECONOMIC GEOGRAPHY," *pae*, vol. 58, no. 1, hlm. 2058–2067, Jan 2021, doi: 10.17762/pae.v58i1.1082.
- [2] A. De Silva, I. Mori, G. Dusek, J. Davis, dan A. Pang, "Automated rip current detection with region based convolutional neural networks," *Coastal Engineering*, vol. 166, hlm. 103859, Jun 2021, doi: 10.1016/j.coastaleng.2021.103859.
- [3] M. Najafzadeh, S. Basirian, dan Z. Li, "Vulnerability of the rip current phenomenon in marine environments using machine learning models," *Results in Engineering*, vol. 21, hlm. 101704, Mar 2024, doi: 10.1016/j.rineng.2023.101704.
- [4] "Pusat Meteorologi Maritim BMKG, 'Rip Currents.'" Diakses: 20 April 2025. [Daring]. Tersedia pada: <https://pusmar.id/glossaries/58/RIP-Currents>
- [5] B. Castelle, J. Dehez, J.-P. Savy, S. Liquet, dan D. Carayon, "Semi-empirical forecast modelling of rip-current and shore-break wave hazards," *Nat. Hazards Earth Syst. Sci.*, vol. 25, no. 7, hlm. 2379–2397, Jul 2025, doi: 10.5194/nhess-25-2379-2025.

-
- [6] N. Rampal, T. Shand, A. Wooler, dan C. Rautenbach, "Interpretable Deep Learning Applied to Rip Current Detection and Localization," *Remote Sensing*, vol. 14, no. 23, hlm. 6048, Nov 2022, doi: 10.3390/rs14236048.
- [7] A. H. Rashid, I. Razzak, M. Tanveer, dan A. Robles-Kelly, "RipDet: A Fast and Lightweight Deep Neural Network for Rip Currents Detection," dalam *2021 International Joint Conference on Neural Networks (IJCNN)*, Shenzhen, China: IEEE, Jul 2021, hlm. 1–6. doi: 10.1109/IJCNN52387.2021.9533849.
- [8] W. Wahyudi, H. Fatchurohman, V. P. R. Natasya, S. Sujantoko, dan L. E. Sembiring, "Rip Current Hazard in Klayar Beach, Pacitan, Indonesia: Inferred from Fluorescent Dye and UAV," *IJMEIR*, vol. 9, no. 2, Jun 2024, doi: 10.12962/j25481479.v9i2.20784.
- [9] Y. Yuan, H. Yang, F. Yu, Y. Gao, B. Li, dan C. Xing, "A wave-resolving modeling study of rip current variability, rip hazard, and swimmer escape strategies on an embayed beach," *Nat. Hazards Earth Syst. Sci.*, vol. 23, no. 11, hlm. 3487–3507, Nov 2023, doi: 10.5194/nhess-23-3487-2023.
- [10] A. Dumitriu, F. Tatui, F. Miron, R. T. Ionescu, dan R. Timofte, "Rip Current Segmentation: A Novel Benchmark and YOLOv8 Baseline Results," dalam *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Vancouver, BC, Canada: IEEE, Jun 2023, hlm. 1261–1271. doi: 10.1109/CVPRW59228.2023.00133.
- [11] A. Dumitriu, F. Tatui, F. Miron, A. Ralhan, R. T. Ionescu, dan R. Timofte, "RipVIS: Rip Currents Video Instance Segmentation Benchmark for Beach Monitoring and Safety," dalam *2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, TN, USA: IEEE, Jun 2025, hlm. 3427–3437. doi: 10.1109/CVPR52734.2025.00325.
- [12] F. Khan, A. De Silva, A. Palinkas, G. Dusek, J. Davis, dan A. Pang, "RipFinder: real-time rip current detection on mobile devices," *Front. Mar. Sci.*, vol. 12, hlm. 1549513, Mei 2025, doi: 10.3389/fmars.2025.1549513.
- [13] F. H. Khan *dkk.*, "RipScout: Realtime ML-Assisted Rip Current Detection and Automated Data Collection Using UAVs," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 18, hlm. 7742–7755, 2025, doi: 10.1109/JSTARS.2025.3543695.
- [14] A. Dumitriu *dkk.*, "AIM 2025 Rip Current Segmentation (RipSeg) Challenge Report," 3 September 2025, *arXiv*: arXiv:2508.13401. doi: 10.48550/arXiv.2508.13401.
- [15] Z. Wang, T. Ding, S. Liang, H. Cui, dan X. Gao, "Workpiece surface defect detection based on YOLOv11 and edge computing," *PLoS One*, vol. 20, no. 7, hlm. e0327546, Jul 2025, doi: 10.1371/journal.pone.0327546.
- [16] F. Wang, "Improving YOLOv11 for marine water quality monitoring and pollution source identification," *Sci Rep*, vol. 15, no. 1, hlm. 21367, Jul 2025, doi: 10.1038/s41598-025-04842-3.
- [17] Y.-S. Lee, M. P. Patil, J. G. Kim, Y. B. Seo, D.-H. Ahn, dan G.-D. Kim, "Hyperparameter Optimization for Tomato Leaf Disease Recognition Based on YOLOv11m," *Plants*, vol. 14, no. 5, hlm. 653, Feb 2025, doi: 10.3390/plants14050653.
- [18] L. He, Y. Zhou, L. Liu, W. Cao, dan J. Ma, "Research on object detection and recognition in remote sensing images based on YOLOv11," *Sci Rep*, vol. 15, no. 1, hlm. 14032, Apr 2025, doi: 10.1038/s41598-025-96314-x.
- [19] Z. Tian, F. Yang, L. Yang, Y. Wu, J. Chen, dan P. Qian, "An Optimized YOLOv11 Framework for the Efficient Multi-Category Defect Detection of Concrete Surface," *Sensors*, vol. 25, no. 5, hlm. 1291, Feb 2025, doi: 10.3390/s25051291.
- [20] Ultralytics, "YOLO11 vs YOLOv8: Detailed Comparison." Diakses: 3 September 2025. [Daring]. Tersedia pada: <https://docs.ultralytics.com/compare/yolo11-vs-yolov8>
- [21] L. T. Ramos dan A. D. Sappa, "A Decade of You Only Look Once (YOLO) for Object Detection: A Review," 3 Agustus 2025, *arXiv*: arXiv:2504.18586. doi: 10.48550/arXiv.2504.18586.
- [22] S. Zhou *dkk.*, "A Lightweight Drone Detection Method Integrated into a Linear Attention Mechanism Based on Improved YOLOv11," *Remote Sensing*, vol. 17, no. 4, hlm. 705, Feb 2025, doi: 10.3390/rs17040705.
- [23] A. Wang, Z. Fu, Y. Zhao, dan H. Chen, "A Remote Sensing Image Object Detection Model Based on Improved YOLOv11," *Electronics*, vol. 14, no. 13, hlm. 2607, Jun 2025, doi: 10.3390/electronics14132607.
-

-
- [24] H. Chen, J. Zhou, dan Q. Zhao, "YOLO-PFS: Improved YOLOv11 for Remote Sensing Object Detection and Recognition," dalam *Advanced Intelligent Computing Technology and Applications*, D.-S. Huang, Y. Pan, W. Chen, dan B. Li, Ed., Singapore: Springer Nature, 2025, hlm. 454–466. doi: 10.1007/978-981-96-9815-8_38.
- [25] R. Hataya, J. Zdenek, K. Yoshizoe, dan H. Nakayama, "Meta Approach to Data Augmentation Optimization," dalam *2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, Waikoloa, HI, USA: IEEE, Jan 2022, hlm. 3535–3544. doi: 10.1109/WACV51458.2022.00359.
- [26] M. A. Lara, I. A. Hameed, dan J. Koziorek, "Anomaly-Focused Augmentation Method for Industrial Visual Inspection," *IEEE Access*, vol. 13, hlm. 89118–89139, 2025, doi: 10.1109/ACCESS.2025.3570075.
- [27] T. Kumar, R. Brennan, A. Mileo, dan M. Bendechache, "Image Data Augmentation Approaches: A Comprehensive Survey and Future Directions," *IEEE Access*, vol. 12, hlm. 187536–187571, 2024, doi: 10.1109/ACCESS.2024.3470122.
- [28] C. Shorten, T. M. Khoshgoftaar, dan B. Furht, "Text Data Augmentation for Deep Learning," *J Big Data*, vol. 8, no. 1, hlm. 101, Des 2021, doi: 10.1186/s40537-021-00492-0.
- [29] V. Li dkk., "A Closer Look at Data Augmentation Strategies for Finetuning-Based Low/Few-Shot Object Detection," dalam *2024 IEEE 14th International Symposium on Industrial Embedded Systems (SIES)*, Okt 2024, hlm. 156–163. doi: 10.1109/SIES62473.2024.10767915.
- [30] P. Alimisis, I. Mademlis, P. Radoglou-Grammatikis, P. Sarigiannidis, dan G. Th. Papadopoulos, "Advances in diffusion models for image data augmentation: a review of methods, models, evaluation metrics and future research directions," *Artif Intell Rev*, vol. 58, no. 4, hlm. 112, Jan 2025, doi: 10.1007/s10462-025-11116-x.
- [31] B. W. Mutaqin, M. Alwi, dan N. M. Adalya, "Analisis Spasial Arus Retas sebagai Upaya Pengurangan Risiko Bencana di Desa Parangtritis Yogyakarta," *Media Komun. Geogr.*, vol. 22, no. 2, hlm. 195, Des 2021, doi: 10.23887/mkg.v22i2.40014.
- [32] B. S. Widartono, M. N. Wachid, D. A. Umarhadi, A. N. Azizah, dan R. D. Cahyo, "Kite Aerial Photography (KAP) for rip current identification in Parangtritis Beach," *E3S Web Conf.*, vol. 76, hlm. 03005, 2019, doi: 10.1051/e3sconf/20197603005.
- [33] E. K. S. H. Muntasib, R. Meilani, dan J. Muthiah, "Ecotourism hazard management in South Beaches of Java, Indonesia," *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 196, hlm. 012021, Nov 2018, doi: 10.1088/1755-1315/196/1/012021.
- [34] A. D. Febriani dan M. D. Kartikasari, "Detecting Avocado Freshness In Real-Time: A Yolo-Based Deep Learning Approach," *J. Tek. Inform. (JUTIF)*, vol. 6, no. 3, hlm. 1485–1502, Jun 2025, doi: 10.52436/1.jutif.2025.6.3.4626.
- [35] N. L. Anggreini, A. Yuliana, D. S. Ramdan, dan W. Al-Dayyeni, "Improving Diabetes Prediction Performance Using Random Forest Classifier with Hyperparameter Tuning," vol. 6, no. 4, 2025.
- [36] I. K. Seneng, P. D. W. Ayu, dan R. R. Huizen, "Comparative Analysis of Augmentation and Filtering Methods in VGG19 and DenseNet121 for Breast Cancer Classification," *J. Tek. Inform. (JUTIF)*, vol. 6, no. 3, hlm. 1131–1146, Jun 2025, doi: 10.52436/1.jutif.2025.6.3.4397.
- [37] A. Kebaili, J. Lapuyade-Lahorgue, dan S. Ruan, "Deep Learning Approaches for Data Augmentation in Medical Imaging: A Review," *J. Imaging*, vol. 9, no. 4, hlm. 81, Apr 2023, doi: 10.3390/jimaging9040081.
- [38] E. Goceri, "Medical image data augmentation: techniques, comparisons and interpretations," *Artif Intell Rev*, vol. 56, no. 11, hlm. 12561–12605, Nov 2023, doi: 10.1007/s10462-023-10453-z.
- [39] S. Sierra, R. Ramo, M. Padilla, dan A. Cobo, "Optimizing deep neural networks for high-resolution land cover classification through data augmentation," *Environ Monit Assess*, vol. 197, no. 4, hlm. 423, Mar 2025, doi: 10.1007/s10661-025-13870-5.
- [40] H. Kwon, S. Choi, W. Woo, dan H. Jung, "Evaluating Segmentation-Based Deep Learning Models for Real-Time Electric Vehicle Fire Detection," *Fire*, vol. 8, no. 2, hlm. 66, Feb 2025, doi: 10.3390/fire8020066.
-

-
- [41] M. R. Sholahuddin *dkk.*, “Optimizing YOLOv8 for Real-Time CCTV Surveillance: A Trade-off Between Speed and Accuracy,” *join*, vol. 8, no. 2, hlm. 261–270, Des 2023, doi: 10.15575/join.v8i2.1196.
- [42] D. Zhu, R. Qi, P. Hu, Q. Su, X. Qin, dan Z. Li, “YOLO-Rip: A modified lightweight network for Rip currents detection,” *Front. Mar. Sci.*, vol. 9, hlm. 930478, Agu 2022, doi: 10.3389/fmars.2022.930478.
- [43] L. Tang dan Q. H. Mahmoud, “A Deep Learning-Based Framework for Phishing Website Detection,” *IEEE Access*, vol. 10, hlm. 1509–1521, 2022, doi: 10.1109/ACCESS.2021.3137636.
- [44] A. Morchid *dkk.*, “IoT-enabled fire detection for sustainable agriculture: A real-time system using flask and embedded technologies,” *Results in Engineering*, vol. 23, hlm. 102705, Sep 2024, doi: 10.1016/j.rineng.2024.102705.
- [45] “Yolov8s-RIP-no-augmentation - v12 2024-05-04 5:06pm.” Diakses: 19 September 2025. [Daring]. Tersedia pada: <https://universe.roboflow.com/rip-txzm1/yolov8s-rip-no-augmentation>
- [46] J. Choi, M. Rajendran, dan Y. Cheol Suh, “Explainable Rip Current Detection and Visualization with XAI EigenCAM,” dalam *2024 26th International Conference on Advanced Communications Technology (ICACT)*, Pyeong Chang, Korea, Republic of: IEEE, Feb 2024, hlm. 1–6. doi: 10.23919/ICACT60172.2024.10471913.