

Klasifikasi Daerah Penangkapan Ikan Menggunakan Algoritma Random Forest dan Support Vector Machine

Classification of Fishing Ground Using Random Forest and Support Vector Machine Algorithms

ANDI KURNIANTO^{1*}, IMAS SUKAESIH SITANGGANG¹, MEDRIA KUSUMA DEWI HARDHIENATA¹

Abstrak

Kondisi ekonomi nelayan tradisional masih berada di lingkaran kemiskinan sehingga diperlukan solusi untuk meningkatkan kesejahteraan. Salah satu solusinya dengan menggunakan teknologi informasi mengenai daerah penangkapan ikan, sehingga nelayan dapat menghemat bahan bakar dan menambah jumlah tangkapan. Informasi daerah penangkapan ikan dapat ditentukan dengan cara mengolah data citra satelit dan menggunakan teknologi *machine learning*. Penelitian ini bertujuan membuat model yang dapat melakukan klasifikasi daerah penangkapan ikan menggunakan algoritma *random forest* dan *support vector machine* pada data citra satelit laut jawa dan sekitarnya dari tahun 2019-2021. Parameter yang digunakan adalah parameter klorofil, suhu permukaan laut, salinitas, ketinggian dan suhu air laut. Hasil penelitian ini menunjukkan parameter klorofil mempunyai peran paling besar yaitu 77.14% dalam menentukan daerah penangkapan ikan. Nilai *precision* yang dihasilkan algoritma *support vector machine* (99.83%) lebih tinggi dibandingkan dengan algoritma *random forest* (99.80%). Meski demikian, model klasifikasi yang dihasilkan algoritma *random forest* mempunyai nilai *accuracy* (99.90%), *recall* (100%) dan *F1 score* (99.90%) yang lebih tinggi dibandingkan algoritma *support vector machine* dengan nilai *accuracy* (99.89%), *recall* (99.96%) dan *F1 score* (99.89%).

Kata Kunci: Daerah penangkapan ikan, *random forest*, *support vector machine*.

Abstract

The economic condition of traditional fishermen is still in a cycle of poverty, so solutions are needed to improve welfare. One solution is to use information technology regarding fishing grounds so that fishermen can save fuel and increase the number of catches. Fishing ground information can be determined by processing satellite image data and using machine learning technology. This research aims to create a model that can classify fishing grounds using random forest and support vector machine algorithms using satellite image data of the Java Sea and its surroundings from 2019-2021 with the parameter's chlorophyll, sea surface temperature, salinity, height of the sea, and water temperature. This research shows that the chlorophyll parameter has the greatest role (77.14%) in determining fishing ground. The precision value produced by the support vector machine algorithm (99.83%) is higher than that produced by the random forest algorithm (99.80%). However, the classification model produced by the random forest algorithm has higher accuracy (99.90%), recall (100%) and F1 score (99.90%) compared to that produced by the support vector machine algorithm, with an accuracy value of (99.89%), recall (99.96%) and F1 score (99.89%).

Keywords: *Fishing ground, random forest, support vector machine*

PENDAHULUAN

Indonesia sebagai negara kepulauan memiliki wilayah laut total sekitar 7,18 juta km² yang didalamnya terkandung sumber daya perikanan berlimpah. Menurut Kementerian Kelautan dan Perikanan, di tahun 2019, sektor perikanan melakukan ekspor mencapai nilai Rp

¹ Departemen Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor, Bogor 16680;

* Penulis Korespondensi: Tel/Faks: 08995027315; Surel: andikurnianto@apps.ipb.ac.id

73,681,883,000.00 mengalami peningkatan 10.1% dari tahun sebelumnya. Berbanding terbalik dengan peningkatan ekspor sektor perikanan, kondisi ekonomi nelayan tradisional masih berada di lingkar kemiskinan dibandingkan nelayan modern. Salah satu faktor penyebabnya adalah minimnya penggunaan teknologi dalam menangkap ikan (Ali 2020). Nelayan tradisional masih mencari ikan di laut dengan cara alami yaitu memahami kondisi alam yang tidak menentu tanpa menggunakan teknologi. Nelayan tradisional menangkap ikan dengan mengandalkan tanda-tanda alam seperti melihat perubahan air dan ombak untuk mengetahui keberadaan habitat ikan (Purwanto *et al.* 2024). Sedangkan nelayan modern dengan modal yang besar dapat membeli dan menggunakan teknologi seperti alat *fish finder* untuk mengetahui keberadaan ikan di laut, sehingga mendapatkan hasil tangkapan ikan yang banyak serta menghemat bahan bakar dan waktu dalam menangkap ikan.

Salah satu cara untuk membantu nelayan tradisional adalah memberikan informasi daerah penangkapan ikan menggunakan teknologi satelit (Zhao *et al.* 2021). Teknologi satelit digunakan untuk melihat anomali lingkungan yang menandakan adanya potensi ikan di wilayah tersebut atau biasa disebut area pengkapan ikan. Anomali seperti suhu permukaan laut, salinitas air, dan klorofil yang mencerminkan kelimpahan fitoplankton dapat digunakan untuk menentukan area penangkapan ikan (Purwanto *et al.* 2024). Selain itu suhu air laut juga diperlukan karena ikan cenderung berada pada area dengan suhu tertentu (Su *et al.* 2024). Begitu juga dengan ketinggian air laut (Zhao *et al.* 2021). Klorofil merupakan parameter yang menunjukkan tingkat produktifitas utama (Sambah *et al.* 2021). Klorofil adalah salah satu indikator untuk mengetahui distribusi dan keberadaan fitoplankton, sehingga klorofil dapat digunakan sebagai parameter untuk mengetahui tingkat kesuburan perairan dan ketersediaan makanan yang menjadi karakteristik area penangkapan ikan (Retraubun *et al.* 2023). Perairan yang subur ditandai dengan banyaknya fitoplankton yang merupakan produsen utama di dasar rantai makanan dan merupakan sumber makanan utama bagi beberapa ikan kecil. Begitu pula zooplankton yang juga menjadi makanan bagi ikan kecil (Sambah *et al.* 2021). Suhu permukaan air laut dilihat menggunakan satelit pada beberapa milimeter teratas air laut, sedangkan suhu laut meliputi pengumpulan nilai untuk permukaannya, kedalamannya, serta penggunaan perangkat lunak untuk memodelkan fluktuasinya (Su *et al.* 2024). Keberadaan dan distribusi dari fitoplankton dipengaruhi oleh suhu (Purwanto *et al.* 2024). Suhu mempengaruhi pertumbuhan, reproduksi, dan pergerakan fitoplankton. Terdapat korelasi linier antara suhu permukaan air laut dan klorofil dengan keberadaan ikan (Suhadha *et al.* 2020)(Zhao *et al.* 2021). Penelitian terkait prakiraan daerah penangkapan ikan menggunakan citra satelit telah dilakukan di beberapa daerah di dalam negeri maupun luar negeri seperti Selat Bali (Ghazali dan Manan, 2012), Laut China Selatan (Zhou *et al.* 2017), Pantai Selatan Blitar (Sukojo, Febriani dan Febriani, 2018), Makassar (Selao *et al.* 2019), Saudi Arabia (Daqamseh *et al.* 2019), Teluk Saleh (Karno dan Dwi, 2019), Laut Semarang (Fitriani *et al.* 2021), Laut Sawu (Muskananfola, Jumsar dan Wirasatriya, 2021) dan Perairan Kabupaten Pidie (Mursyidin dan Musfikar, 2021).

Machine Learning (ML) merupakan salah satu teknologi *Artificial Intelligence* (AI) untuk menyelesaikan masalah atau otomasi. ML dapat melakukan otomasi dalam bidang klasifikasi dan prediksi. Penelitian sebelumnya memprediksi suhu permukaan laut menggunakan data satelit *Aqua MODerate resolution Imaging Spectroradiometer* (MODIS) di Laut Cina Selatan menggunakan *Support Vector Machine* (SVM) (Nawi *et al.* 2021). *Random forest* (RF) juga diimplementasikan untuk memprediksi suhu permukaan laut, menghasilkan nilai RMSE 0.356 (Kumar *et al.* 2021). Penelitian Nawi *et al.* (2021) dan Kumar *et al.* (2021) hanya memprediksi suhu pemukaan laut dan klorofil menggunakan SVM dan RF namun belum mengklasifikasi daerah penangkapan ikan, sehingga diperlukan model untuk melakukan klasifikasi daerah penangkapan ikan.

Penelitian ini bertujuan untuk membuat model klasifikasi daerah penangkapan ikan menggunakan algoritma SVM dan RF berdasarkan parameter klorofil, suhu permukaan laut, salinitas, ketinggian, dan suhu air laut. Hasil penelitian ini diharapkan dapat memberikan

informasi mengenai daerah penangkapan ikan kepada nelayan sehingga nelayan dapat menangkap ikan di daerah penangkapan ikan untuk meningkatkan kesejahteraan nelayan.

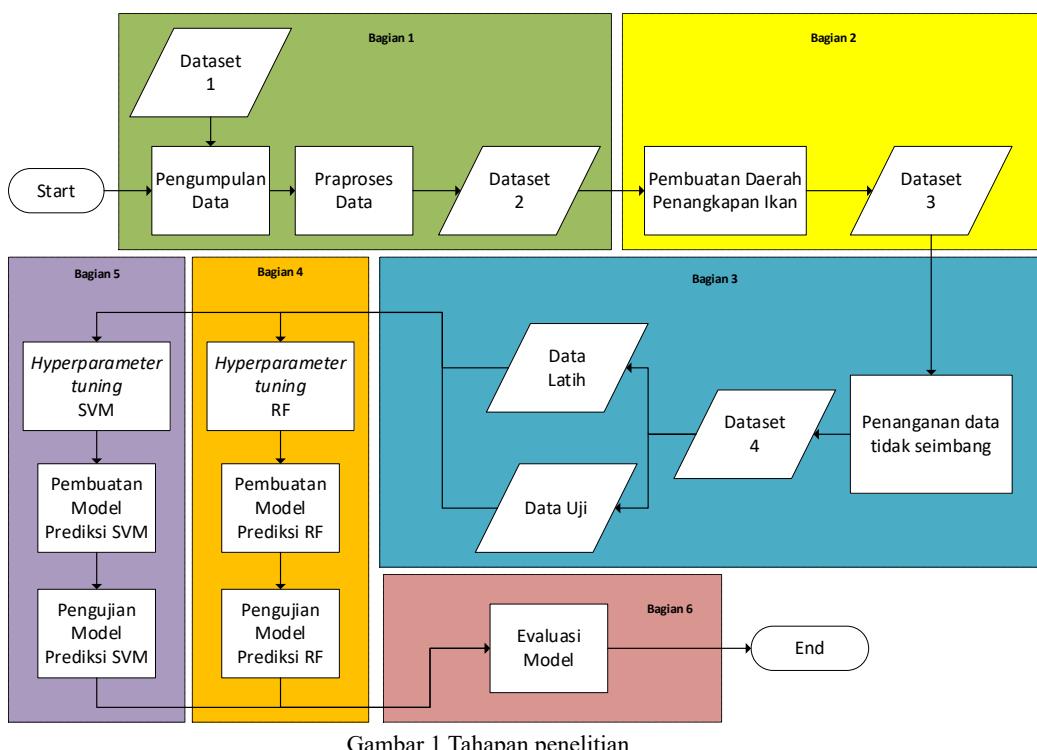
METODE

Tahapan penelitian ini dibagi menjadi enam bagian yaitu pengumpulan data, pembuatan daerah penangkapan ikan, penanganan data tidak seimbang, pembuatan model klasifikasi menggunakan algoritma RF, pembuatan model klasifikasi menggunakan algoritma SVM, dan analisa. Detail tahapan penelitian dapat dilihat pada Gambar 1.

Bagian 1: Pengumpulan dan Praproses Data

Dataset 1 merupakan data citra satelit data laut yang terletak di garis lintang $14^{\circ}0'0''\text{S}$ hingga $2^{\circ}0'0''\text{S}$ dan di garis bujur $102^{\circ}0'0''\text{E}$ hingga $128^{\circ}0'0''\text{E}$ dari tahun 2019 sampai 2021. Data citra satelit yang digunakan untuk menentukan daerah penangkapan ikan adalah citra klorofil dan suhu permukaan laut merupakan hasil deteksi *Aqua MODerate resolution Imaging Spectroradiometer* (MODIS). Sedangkan informasi mengenai salinitas, ketinggian, dan suhu air laut diambil dari *HYbrid Coordinate Ocean Model* (HYCOM) *National Oceanic and Atmospheric Administration* (NOAA). Data citra satelit yang diunduh berupa file dengan tipe data NC file (NetCDF), dengan menggunakan bahasa pemrograman python NC file kemudian di ekstrak menjadi file *Comma-separated values* (CSV).

Praproses data terdiri dari pembersihan data, seleksi variabel data, dan penggabungan data. Pembersihan data dilakukan untuk menghilangkan data yang tidak mendukung penelitian dan *missing value*. Seleksi variabel data dilakukan untuk mendapatkan data yang relevan. Praproses data untuk menghilangkan *missing value* dengan menggunakan *interpolasi* data. Setelah data tidak terdapat *missing value*, maka data digabungkan sesuai dengan yang digunakan dalam pembuatan model klasifikasi menjadi dataset 2.



Gambar 1 Tahapan penelitian

Bagian 2: Pembuatan Daerah Penangkapan Ikan

Hasil praproses Data citra satelit *Aqua MODIS* selanjutnya dilakukan proses *cropping* wilayah. Setelah di *cropping*, data tersebut selanjutnya dikonversi menjadi data vektor. Kemudian data diolah berdasarkan dua parameter dengan nilai yang telah ditentukan untuk

menghasilkan daerah penangkapan ikan. Daerah potensi penangkapan ikan mempunyai nilai kandungan klorofil lebih dari 0.5 mg/m³ dengan suhu permukaan laut 26°C-29°C (Mursyidin *et al.* 2015).

Bagian 3: Penanganan Data yang Tidak Seimbang

Tahap selanjutnya yaitu melakukan pengecekan perbandingan jumlah kelas positif dan negatif. Jika terdapat perbedaan jumlah yang sangat jauh antara kelas mayor dan kelas minor maka data bersifat *imbalance*. *Imbalancing* data dapat mengakibatkan nilai akurasi dari model klasifikasi menjadi rendah (Weiss dan Provost, 2001)(Pujianto *et al.* 2022). Metode untuk mengatasi data yang tidak seimbang adalah dengan *undersampling* dan *oversampling*. *Undersampling* adalah metode *balancing* data dengan mengurangi jumlah kelas mayor sedangkan *oversampling* adalah metode *balancing* data dengan menambah jumlah kelas minor.

Bagian 4: Model Klasifikasi Daerah Penangkapan Ikan Menggunakan Algoritma RF

Tahap pembuatan model klasifikasi merupakan tahapan pembentukan model prediksi dengan menerapkan algoritma ML RF menggunakan *dataset* 4. Pemodelan RF membutuhkan pemberian nilai parameter untuk menghasilkan suatu model klasifikasi. Parameter yang perlu diberi nilai yaitu parameter jumlah banyaknya pohon keputusan, nilai maksimal kedalaman pohon keputusan, dan jumlah maksimal daun pada setiap node. *Hyperparameter tuning* dapat menentukan parameter terbaik untuk RF sehingga dapat membentuk model klasifikasi yang baik. RF dapat menangani data yang besar, multikolinieritas, cepat, dan tidak sensitif terhadap *overfitting*. Algoritma RF (Breiman 2001)(Ganaie *et al.* 2022) adalah sebagai berikut:

1. Membuat dataset yang berukuran Z dengan cara *bootstrap* dari data latih.
2. Membangun pohon prediksi dengan menggunakan *bootstrapped* dataset, mengulangi langkah-langkah berikut secara rekursif untuk setiap simpul pohon, hingga ukuran simpul minimum:
 - a. Memilih m peubah dari p peubah yang ada ($m < p$).
 - b. Memilih peubah terbaik dari m peubah untuk menjadi simpul pemisah.
 - c. Pisah simpul menjadi dua simpul anak.
3. Mengulang langkah 1 dan 2 hingga diperoleh B pohon.
4. Prediksi akhir untuk data baru dilakukan dengan menggabungkan hasil prediksi dari setiap pohon di dalam *forest*. Jika RF digunakan untuk klasifikasi, prediksi data baru dilakukan dengan menggunakan suara terbanyak.

Bagian 5: Model Klasifikasi Daerah Penangkapan Ikan Menggunakan Algoritma SVM

Model klasifikasi daerah penangkapan ikan algoritma SVM dibangun dengan menggunakan data dan parameter yang sama dengan pembangunan model algoritma RF. *Hyperparameter tuning* untuk SVM dilakukan dengan menentukan parameter C dan *gamma*. Parameter C adalah parameter yang mengontrol kesalahan klasifikasi. Semakin besar nilai C, maka semakin kecil *margin*. Parameter *gamma* merupakan parameter yang menentukan bentuk *boundary*. Pembuatan model prediksi ini menggunakan empat fungsi kernel dasar yang biasa digunakan pada SVM, yaitu *linear*, *polynomial*, *Radial Basis Function* (RBF), dan *sigmoid*. Rumus kernel SVM didefinisikan pada Persamaan 1, Persamaan 2, Persamaan 3, dan Persamaan 4 (Wang *et al.* 2010)(Kuter 2021)namely, random forests (RFs):

Kernel *linear*:

$$K(x, y) = x \cdot y \quad (1)$$

Kernel *polynomial*:

$$K(x, y) = (x \cdot y + 1)^d \quad (2)$$

Kernel RBF:

$$K(x, y) = \exp\left(-\frac{|x - y|^2}{2\sigma^2}\right) \quad (3)$$

Kernel sigmoid:

$$K(x, y) = \tanh(v(x, y) + c) \quad (4)$$

Setelah didapatkan model prediksi dengan SVM, maka tahapan selanjutnya adalah pengujian model dengan menggunakan data uji.

Bagian 6: Evaluasi Model

Evaluasi dilakukan pada masing-masing model klasifikasi dengan algoritma RF dan SVM. Model klasifikasi yang telah terbentuk dihitung nilai akurasi dan nilai ketelitiannya dengan *confusion matrix*. *Confusion matrix* diilustrasikan pada Tabel 1. *Confusion matrix* berisi data prediksi dan aktual sehingga dapat diketahui nilai *accuracy*, *precision*, *recall*, dan *F1 score*. *Accuracy* yaitu nilai akurasi model mengklasifikasikan dengan benar. *Precision* adalah kemampuan model untuk tidak memberi label positif pada data negatif. *Recall* merupakan kemampuan model untuk menemukan semua data positif. Sedangkan *F1 score* adalah perbandingan rata-rata *precision* dan *recall*. Rumus *accuracy*, *precision*, *recall* dan *F1 score* dapat dihitung dengan rumus (Powers 2020):

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$\text{precision} = \frac{TP}{TP + FP} \quad (6)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (7)$$

$$\text{F1 score} = 2 \frac{\text{precision} * \text{recall}}{\text{precision} + \text{recall}} \quad (8)$$

Dari perhitungan *accuracy*, *precision*, *recall*, dan *F1 score* dapat dianalisis model mana yang lebih baik diantara model prediksi menggunakan algoritma SVM dan RF.

Tabel 1 Ilustrasi *confusion matrix*

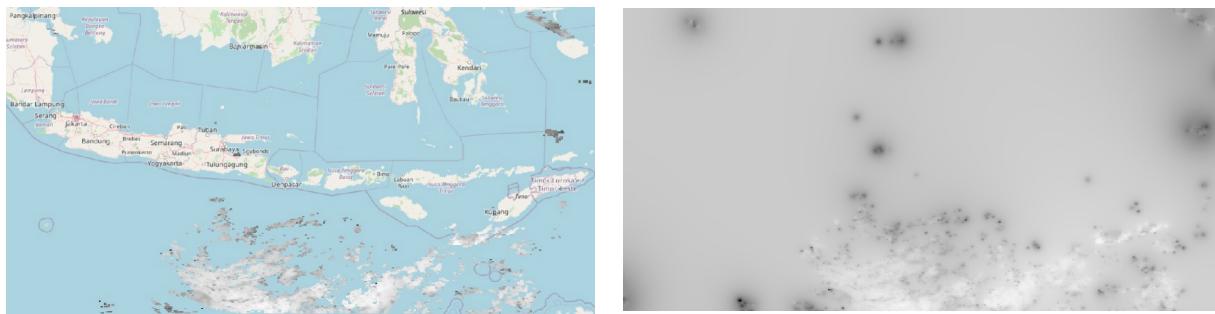
Prediksi	Aktual	
	True	False
True	True Positif (TP)	False Positif (FP)
False	False Negatif (FN)	True Negatif (TN)

HASIL DAN PEMBAHASAN

Praproses Data

Dataset 1 pada penelitian ini perlu dilakukan praproses data dikarenakan terdapat *feature* yang tidak digunakan dalam pembuatan model klasifikasi dan terdapat *missing value*. Setelah dilakukan praproses data, dataset mempunyai *feature latitude*, *longitude*, *chl*, *sst*, *salinity*, *water temperature*, dan *water surface elevation*. Dataset penelitian merupakan dataset spatial yaitu dataset yang mempunyai sistem koordinat sehingga untuk mengatasi permasalahan *missing value* maka dilakukan proses interpolasi dengan menggunakan metode *inverse distance weighting* (IDW). IDW adalah salah satu metode untuk menaksir suatu nilai pada lokasi yang

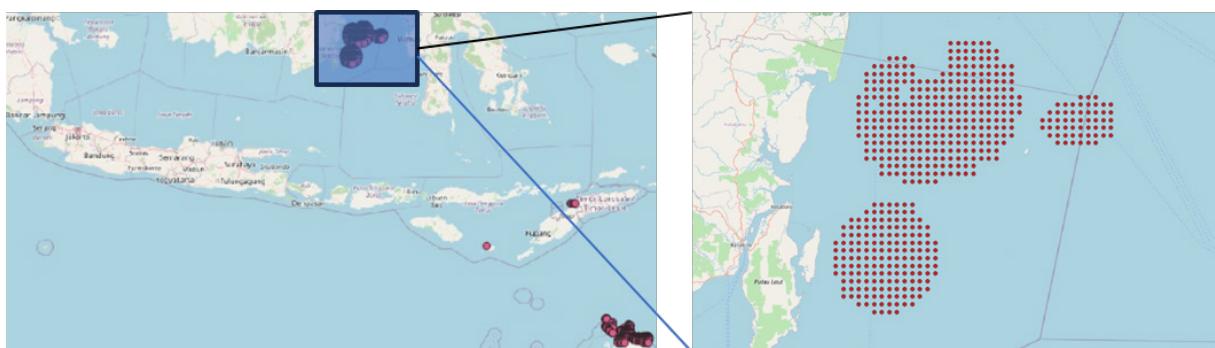
tidak mempunyai nilai. Nilai tersebut diambil berdasarkan nilai pada lokasi disekitarnya (Li *et al.* 2024). IDW memberikan nilai bobot berdasarkan jarak lokasi. Semakin dekat jarak lokasi maka semakin mirip nilai yang ditaksir. Proses IDW dilakukan pada seluruh *dataset* sehingga tidak terdapat *missing value*. Gambaran sebelum proses IDW dan sesudah proses IDW dapat dilihat pada Gambar 2. Setelah dipastikan tidak terdapat *missing value*, maka *dataset* digabungkan menjadi satu.



Gambar 2 Data sebelum proses IDW dan data sesudah proses IDW

Pembuatan Daerah Penangkapan Ikan

Daerah penangkapan ikan dibuat dengan cara melakukan penyaringan nilai klorofil $> 0.5 \text{ mg/m}^3$ dan suhu permukaan laut $26^\circ\text{C}-29^\circ\text{C}$ seperti pada Gambar 3. Pelabelan daerah penangkapan ikan diberikan pada setiap baris *dataset*. Daerah penangkapan ikan merupakan kelas dari *dataset* untuk membuat model klasifikasi. Kelas merupakan target prediksi dari model klasifikasi. Proses pelabelan membuat *dataset* 3 mempunyai *feature chlo, sst, salinity, water temperature, water surface elevation*, dan daerah penangkapan ikan. Nilai dari *class* daerah penangkapan ikan terdiri dari 2 nilai yaitu “yes” dan “no” untuk lokasi yang berpotensi atau tidak daerah yang terdapat ikan.



Gambar 3 Hasil penyaringan daerah penangkapan ikan

Penanganan Data Tidak Seimbang

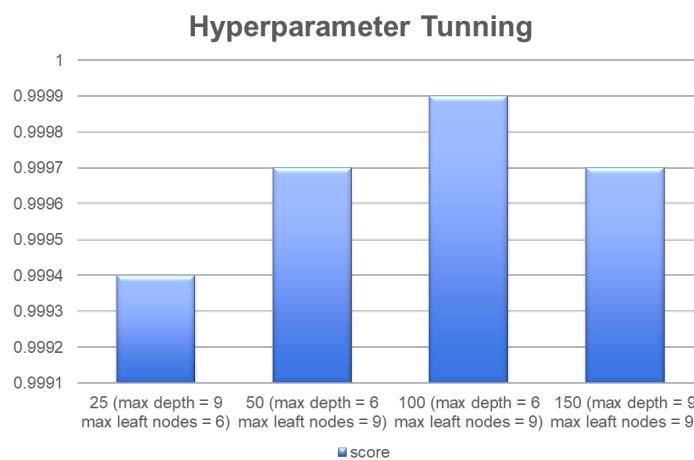
Perhitungan kelas positif dan negatif dilakukan pada *Dataset* 3 untuk mengetahui *imbalancing* data. Kelas positif dari *dataset* 3 sangat sedikit jika dibandingkan dengan kelas negatif. Kelas positif berjumlah 3,928,193 dan kelas negatif sebanyak 29,440,376. Persentase kelas positif 11.77% sedangkan kelas negatif 89.23%. Berdasarkan hasil perbandingan ini, *dataset* termasuk *imbalancing* data sehingga perlu dilakukan *balancing* data. Karena jumlah *dataset* banyak, maka metode yang digunakan adalah *random undersampling* dengan *sample* data kelas mayor sejumlah kelas minor. Tahap selanjutnya yaitu membagi *dataset* 4 menjadi data latih dan data uji. Presentase pembagian data latih dan data uji yaitu 80% data latih dan 20% data uji. Data latih dan data uji akan dimodelkan menggunakan ML, RF, dan SVM.

Klasifikasi Daerah Penangkapan Ikan dengan Algoritma RF

Tahapan sebelum membuat model klasifikasi menggunakan algoritma RF yaitu menentukan parameter terbaik dengan *hyperparameter tuning*. Parameter yang ditentukan nilainya untuk *hyperparameter tuning* adalah *n_estimators= 25, 50, 100, 150; max_depth= 3,*

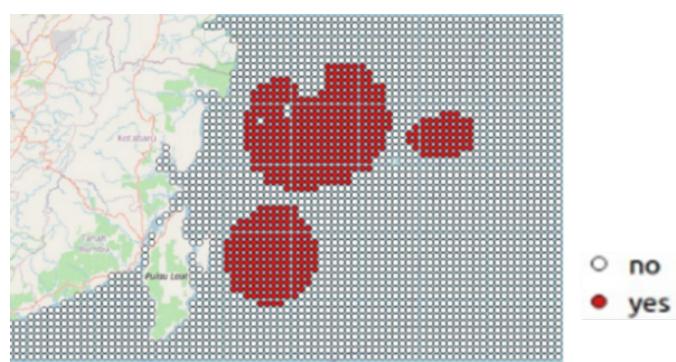
$6, 9; max_leaf_nodes= 3, 6, 9$. Hyperparameter tuning dengan parameter tersebut mempunyai 36 kombinasi parameter. Setelah diproses maka setiap kombinasi mendapatkan *score*, semakin tinggi nilai *score* maka kombinasi parameter semakin bagus.

Parameter $n_estimators= 25$ mendapatkan *score* 0.9994 dengan kombinasi parameter $max_depth= 9$ dan $max_leaf_nodes= 6$. Parameter $n_estimators= 50$ mempunyai hasil hyperparameter tuning dengan kombinasi parameter $max_depth= 6$ dan $max_leaf_node'= 9$ yaitu 0.9997. Hasil hyperparameter tuning parameter $n_estimators= 100$ mempunyai *score* 0.9999 dengan parameter $max_depth= 6$ dan $max_leaf_nodes= 9$, merupakan kombinasi parameter terbaik diantara seluruh parameter ‘*n_estimators*’. Hasil hyperparameter tuning dengan parameter $n_estimators= 150$ mempunyai *score* 0.9997 dengan kombinasi parameter $max_dept'= 9$ dan $max_leaf_nodes= 9$. Hasil Hyperparameter tuning RF dapat dilihat pada Gambar 4.



Gambar 4 Hasil pemodelan klasifikasi RF

Setelah mendapatkan parameter terbaik dengan *hyperparameter tuning* maka tahapan selanjutnya adalah pembuatan model klasifikasi menggunakan algoritma RF, yang dilatih menggunakan data latih. Model klasifikasi yang telah terbentuk kemudian diuji menggunakan data uji dan divisualisasikan kedalam peta untuk melihat hasil pemodelan klasifikasi RF seperti pada Gambar 5.

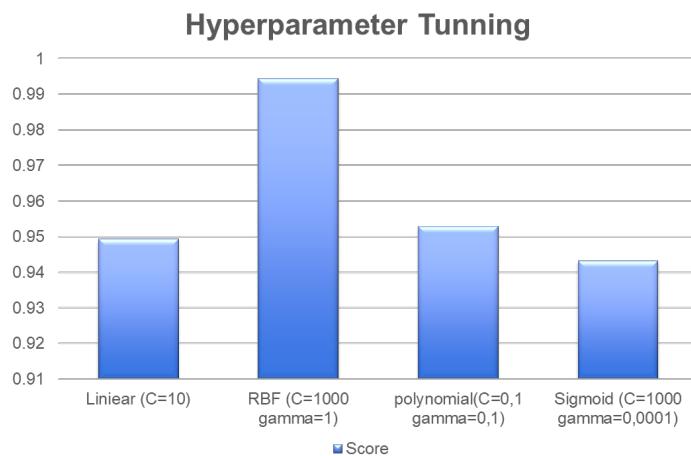


Gambar 5 Hasil pemodelan klasifikasi RF

Klasifikasi Daerah Penangkapan Ikan dengan Algoritma SVM

Hyperparameter tuning merupakan tahapan awal dalam membuat model klasifikasi menggunakan algoritma SVM untuk menentukan parameter terbaik. Parameter C ditentukan bernilai 0.1, 1, 10, 100, dan 1000 sedangkan parameter *gamma* ditentukan bernilai 1, 0.1, 0.01, 0.001, dan 0.0001. Pada Gambar 6, hasil hyperparameter tuning parameter *kernel linear* kombinasi parameter $C= 10$ mendapatkan nilai 0.9493 dengan berbagai nilai *gamma*. Score tertinggi pada *kernel rbf* merupakan kombinasi parameter terbaik dari *kernel* yang ada dengan

nilai 0.9944 dimana parameter $C = 1000$ dan $gamma = 1$. Score tertinggi *kernel poly* bernilai 0.9529 dengan kombinasi parameter $C = 0.1$ dan $gamma = 0.1$. Parameter kombinasi $C = 1000$ dan $gamma = 0.0001$ merupakan hasil *hyperparameter tuning* menggunakan parameter *kernel sigmoid* dengan nilai tertinggi 0.9432.



Gambar 6 Hasil pemodelan dengan algoritma SVM

Berdasarkan hasil *hyperparameter tuning* dengan parameter terbaik $C = 1000$ dan $gamma = 1$ pada kernel *RBF* maka tahapan selanjutnya adalah pembuatan model klasifikasi menggunakan algoritma SVM. Pembuatan model klasifikasi menggunakan parameter terbaik dengan melatih model klasifikasi dengan data latih. Tahap selanjutnya, model klasifikasi menggunakan algoritma SVM diuji menggunakan data uji dan divisualisasikan kedalam peta seperti pada Gambar 7.



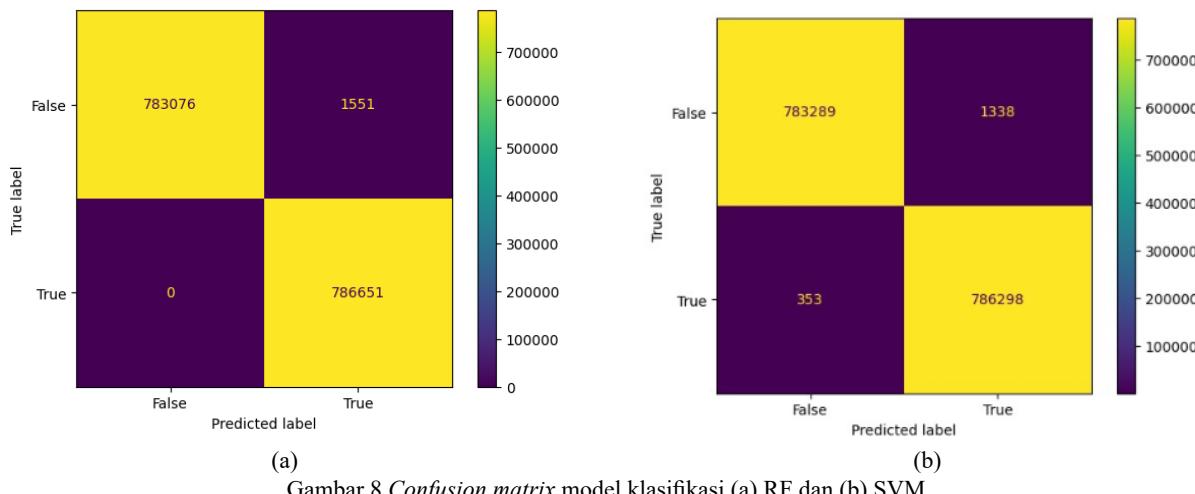
Gambar 7 Hasil pemodelan klasifikasi SVM

Evaluasi Model Klasifikasi

Hasil pengujian model klasifikasi menggunakan algoritma RF memprediksi daerah yang berpotensi merupakan daerah penangkapan ikan (TP) sebesar 786,651 titik sesuai dengan aktualnya dan 1551 tidak sesuai dengan aktual (FP). Sedangkan daerah yang tidak berpotensi daerah penangkapan ikan (TN) sebesar 783,076 titik yang sesuai dengan aktual dan 0 tidak sesuai (FN). Berdasarkan Gambar 8(a) nilai prediksi sebagian besar benar sehingga mempunyai nilai *accuracy*= 99.90%, *precision*= 99.80%, *recall*= 100%, dan *F1 score*= 99.90%. Model klasifikasi menggunakan algoritma RF masih terdapat sedikit kesalahan pada FP sedangkan FN tidak ada. Dari *confusion matrix*, model klasifikasi menggunakan algoritma RF mempunyai nilai yang baik untuk mengklasifikasikan daerah penangkapan ikan.

Model klasifikasi RF juga memberikan informasi mengenai *importance feature*, yaitu peran sebuah *feature* dalam pembuatan model klasifikasi RF. Hasil dari *importance feature*. parameter klorofil mempunyai peran paling besar sebesar 77.14%, kemudian suhu permukaan laut sebesar 12.46%. Parameter ketiga yaitu salinitas 6.49%, keempat suhu air laut 3.81%, dan terakhir ketinggian air laut 0.09%.

Parameter klorofil sangat berpengaruh terhadap penentuan daerah penangkapan ikan. Hal ini dikarenakan klorofil sebagai sumber makanan ikan sehingga jika di daerah terdapat klorofil maka di daerah tersebut terdapat ikan (Retraubun *et al.* 2023). Parameter suhu permukaan laut, salinitas, dan suhu air laut terdapat pengaruh untuk daerah penangkapan ikan namun kecil pengaruhnya, sedangkan ketinggian air laut tidak berpengaruh terhadap daerah penangkapan ikan.



Gambar 8 Confusion matrix model klasifikasi (a) RF dan (b) SVM

Model klasifikasi daerah penangkapan ikan menggunakan algoritma SVM memprediksi data uji menghasilkan prediksi daerah yang berpotensi merupakan daerah penangkapan ikan sebesar (TP) 786,298 titik sesuai dengan aktualnya dan sebesar 1338 titik tidak sesuai dengan aktual (FP). Sedangkan daerah yang tidak berpotensi daerah penangkapan ikan (TN) sebesar 783,289 titik yang sesuai dengan aktual dan 356 titik prediksi yang salah (FN). Model klasifikasi menggunakan algoritma SVM mempunyai nilai *accuracy*= 99.89%, *precision*= 99.83%, *recall*= 99.96%, dan *F1 score*= 99.89% sesuai dengan perhitungan dari Gambar 8(b).

SIMPULAN

Model klasifikasi daerah penangkapan ikan menggunakan algoritma RF dan SVM dapat digunakan untuk mengklasifikasi daerah penangkapan ikan karena mempunyai nilai *accuracy*, *precision*, *recall*, dan *F1 score* yang tinggi. Hasil analisa model klasifikasi yang dihasilkan algoritma SVM mempunyai nilai *precision* yang lebih tinggi 0.03% dibanding dengan yang dihasilkan algoritma RF. Meski demikian model klasifikasi yang dihasilkan algoritma RF mempunyai nilai *accuracy* (0.01%), *recall* (0.04%), dan *F1 score* (0.01%) yang lebih tinggi dibandingkan dengan yang dihasilkan algoritma SVM, sehingga model klasifikasi yang dihasilkan algoritma RF lebih baik dan tepat mengklasifikasi daerah penangkapan ikan.

DAFTAR PUSTAKA

- Ali AA. 2020. Identifikasi Dan Pemberdayaan Masyarakat Miskin Nelayan Tradisional. *Pondasi*. 25(1):37. <https://doi.org/10.30659/pondasi.v25i1.13035>.
- Breiman L. 2001. Random Forests. *Kluwer Academic Publishers. Manufactured in The Netherlands*, Machine Le(45):5–32. https://doi.org/10.1007/978-3-030-62008-0_35.
- Daqamseh ST, Al-Fugara A, Pradhan B, Al-Oraiqa A, Habib M. 2019. MODIS Derived Sea Surface Salinity, Temperature, and Chlorophyll-a Data for Potential Fish Zone Mapping: West Red Sea Coastal Areas, Saudi Arabia. *Sensors (Switzerland)*. 19(9). <https://doi.org/10.3390/s19092069>.
- Fitriani N, *et al.* 2021. Analisis Pemetaan Daerah Potensial Penangkapan Ikan (Fishing Ground) Dengan Menggunakan Citra Satelit Terra Modis dan parameter Oseanografi. *Geodesi Undip*. 8(1):170–179.

- Ganaie MA, Hu M, Malik AK, Tanveer M, Suganthan PN. 2022. Ensemble Deep Learning: A Review. *Engineering Applications of Artificial Intelligence* [online] 115(July):105151. <https://doi.org/10.1016/j.engappai.2022.105151>.
- Ghazali I, Manan A. 2012. Prakiraan Daerah Penangkapan Ikan di Selat Bali Berdasarkan Data Citra Satelit. *Jurnal Ilmiah Perikanan dan Kelautan*. [online] 4(1):87–92. Available at: <<http://oceancolor.gsfc.nasa>>.
- Karno E, Dwi A. 2019. Studi Pemetaan Daerah Penangkapan Ikan Di Perairan Teluk Saleh Berdasarkan Persebaran Suhu Permukaan Laut Menggunakan Citra Satelit VIIRS-NPP Mapping of Fishing Area in Saleh Bay Water Based On Sea Surface Temperature Using Satellite VIIRS-NPP Image. *Seminar Nasional Penginderaan Jauh ke-6 Tahun 2019 Studi*. (January):418–429.
- Kumar C, Podestá G, Kilpatrick K, Minnett P. 2021. A Machine Learning Approach to Estimating The Error in Satellite Sea Surface Temperature Retrievals. *Remote Sensing of Environment*. 255. <https://doi.org/10.1016/j.rse.2020.112227>.
- Kuter S. 2021. Completing The Machine Learning Saga in Fractional Snow Cover Estimation from MODIS Terra Reflectance Data: Random Forest versus Support Vector Regression. *Remote Sensing of Environment*. [online] 255(April 2020):112294. <https://doi.org/10.1016/j.rse.2021.112294>.
- Li F, Shang Z, Liu Y, Shen H, Jin Y. 2024. Inverse Distance Weighting and Radial Basis Function Based Surrogate Model for High-Dimensional Expensive Multi-Objective Optimization. *Applied Soft Computing*. [online] 152(December 2023):111194. <https://doi.org/10.1016/j.asoc.2023.111194>.
- Mursyidin M, Musfikar R. 2021. Pemetaan Zona Potensi Pengakapan Ikan Perairan Kabupaten Pidie Menggunakan Citra Satelit Aqua Modis. *CIRCUIT: Jurnal Ilmiah Pendidikan Teknik Elektro*. 5(1):43. <https://doi.org/10.22373/crc.v5i1.8248>.
- Mursyidin M, Munadi KZAM. 2015. Prediksi Zona Tangkapan Ikan Menggunakan Citra Klorofil-a Dan Citra Suhu Permukaan Laut Satelit Aqua MODIS Di Perairan Pulo Aceh. *Jurnal Rekayasa Elektrika*. 11(5):176. <https://doi.org/10.17529/jre.v11i5.2973>.
- Muskananfola MR, Jumsar, Wirasatriya A. 2021. Spatio-Temporal Distribution of Chlorophyll-A Concentration, Sea Surface Temperature and Wind Speed Using Aqua-Modis Satellite Imagery Over The Savu Sea, Indonesia. *Remote Sensing Applications: Society and Environment*. 22(February):100483. <https://doi.org/10.1016/j.rsase.2021.100483>.
- Nawi WIAWM, Lola MS, Zakariya R, Zainuddin NH, Abd Hamid AAK, Aruchunan E, Nazzrol NSA. 2021. Improved of Forecasting Sea Surface Temperature Based On Hybrid Arima and Support Vector Machines Models. *Malaysian Journal of Fundamental and Applied Sciences*. 17(5):609–620. <https://doi.org/10.11113/MJFAS.V17N5.2356>.
- Powers DMW. 2020. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation. [online] (January 2008). Available at: <<http://arxiv.org/abs/2010.16061>>.
- Pujianto U, Akbar MI, Lassela NT, Sutaji D. 2022. The Effect of Resampling on Classifier Performance: an Empirical Study. *Knowledge Engineering and Data Science*. 5(1):87. <https://doi.org/10.17977/um018v5i12022p87-100>.
- Purwanto AD, Wisha UJ, Suhadha AG, Permatasari D, Rahmawati E. 2024. Seasonal Potential Fishing Zone Model in The Regional Fisheries Management of Indonesia (WPP-RI) 716 Based on Remote Sensing Satellite Data. *Kuwait Journal of Science*. 51(1). <https://doi.org/10.1016/j.kjs.2023.10.002>.
- Retraubun ASW, Tubalawony S, Masrikat JAN, Hukubun RD. 2023. Analysis of Sea Surface Temperature and Chlorophyll-A and Its Relationship with Catch Results Flying Fish Eggs in the Waters of the Kei Islands. *Jurnal Penelitian Pendidikan IPA*. 9(12):11311–11324. <https://doi.org/10.29303/jppipa.v9i12.6240>.

- Sambah AB, Muamanah A, Harlyan LI, Lelono TD, Iranawati F, Sartimbula A. 2021. Sea Surface Temperature and Chlorophyll-A Distribution from Himawari Satellite and Its Relation to Yellowfin Tuna in The Indian Ocean. *AACL Bioflux*. 14(2):897–909.
- Selao A, Malik AA, Yani FI, Mallawa A, Safruddin. 2019. Remote Chlorophyll-a and SST to Determination of Fish Potential Area in Makassar Strait Waters Using MODIS Satellite Data. *IOP Conference Series: Earth and Environmental Science*. 270(1). <https://doi.org/10.1088/1755-1315/270/1/012047>.
- Su S, Mao Q, Li Y, Li H, Leng J, Lu C. 2024. Deep Learning-Based Fishing Ground Prediction for Albacore and Yellowfin Tuna in The Western and Central Pacific Ocean. *Fisheries Research*. [online] 278(December 2023):107103. <https://doi.org/10.1016/j.fishres.2024.107103>.
- Suhadha, Argo G, Ibrahim A. 2020. Association Study Between Thermal Front Phenomena and Bali Sardinella Fishing Areas in Bali Strait. *Indonesian Journal of Geography*. [online] 52(112):154–162. <https://doi.org/http://dx.doi.org/10.22146/ijg.51668>.
- Sukojo BM, Febriani ER, Febriani ER. 2018. Pemanfaatan Citra Modis Level 1b Dalam Pembuatan Peta Prakiraan Daerah Penangkapan Ikan (Studi Kasus : Pantai Selatan Blitar). *Geoid*. 13(1):34. <https://doi.org/10.12962/j24423998.v13i1.3638>.
- Wang AN, Zhao Y, Hou YT, Li YL. 2010. a Novel Construction of SVM Compound Kernel Function. *2010 International Conference on Logistics Systems and Intelligent Management. ICLSIM 2010*. 3:1462–1465. <https://doi.org/10.1109/ICLSIM.2010.5461210>.
- Weiss GM, Provost F. 2001. The Effect of Resampling on Classifier Performance: an Empirical Study. *Technical Report MLTR-43, Dept. of Computer Science, Rutgers Univ*. <https://doi.org/10.17977/um018v5i12022p87-100>.
- Zhao H, Feng Y, Dong C, Li Z. 2021. Spatiotemporal Distribution of Decapterus Maruadsi in Spring and Autumn in Response to Environmental Variation in The Northern South China Sea. *Regional Studies in Marine Science*. [online] 45:101811. <https://doi.org/10.1016/j.rsma.2021.101811>.
- Zhou WF, Xu HY, Li AZ, Ji SJ. 2017. Zone Statistics of The Oceanic Primary Productivity for The Traditional Fishing Areas of The Open South China Sea Based on MODIS Products. *Applied Ecology and Environmental Research*. 15(3):1013–1024. https://doi.org/10.15666/aeer/1503_10131024.