

ANALISIS REGRESI NON-LINIER PRODUKSI PERIKANAN TANGKAP MENGUNAKAN PENDEKATAN *ENSEMBLE LEARNING* BERBASIS INDIKATOR ATMOSFER

Agung Wilis Nurcahyo, Sri Redjeki

Magister Teknologi Informasi, Universitas Teknologi Digital Indonesia
Jl. Raya Janti Jl. Majapahit No.143, Kabupaten Bantul, Daerah Istimewa Yogyakarta
Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), Nganjuk, Jawa Timur
students.agungwilis24@mti.utdi.ac.id

ABSTRAK

Produksi perikanan tangkap laut merupakan sistem kompleks yang dipengaruhi oleh interaksi non-linier berbagai faktor lingkungan, sementara ketersediaan data oseanografi historis pada skala kabupaten/kota masih terbatas. Penelitian ini bertujuan menganalisis hubungan regresi non-linier antara indikator geofisika atmosfer darat dan volume produksi perikanan tangkap laut di Provinsi Jawa Timur menggunakan pendekatan statistik berbasis *machine learning*. Data yang digunakan merupakan data tahunan periode 2020–2023 yang meliputi suhu udara, kelembapan, curah hujan, durasi penyinaran matahari, dan kecepatan angin sebagai variabel prediktor. Variabel respon berupa volume produksi perikanan tangkap ditransformasikan secara logaritmik untuk menstabilkan varians dan mengurangi pengaruh pencilan. Pemodelan dilakukan menggunakan *Random Forest* sebagai estimator regresi non-parametrik dan dibandingkan dengan *Decision Tree* sebagai model dasar. Evaluasi kinerja model menggunakan *Mean Absolute Error*, *Root Mean Squared Error*, dan koefisien determinasi menunjukkan bahwa pendekatan ensemble menghasilkan kesalahan prediksi yang lebih rendah dan estimasi yang lebih stabil dibandingkan model pohon tunggal. Analisis kepentingan fitur mengindikasikan bahwa suhu udara dan kelembapan merupakan variabel dengan kontribusi dominan. Temuan ini menunjukkan bahwa indikator atmosfer darat dapat dimanfaatkan secara aplikatif sebagai proksi lingkungan dalam analisis produksi perikanan tangkap dengan keterbatasan data laut langsung.

Kata kunci : *regresi non-linier, ensemble learning, Random Forest, indikator atmosfer, analisis statistik, perikanan tangkap.*

1. PENDAHULUAN

Produksi perikanan tangkap laut merupakan salah satu sektor strategis yang berperan penting dalam mendukung ketahanan pangan dan perekonomian regional di Indonesia, khususnya di wilayah pesisir [1], [2]. Provinsi Jawa Timur dikenal sebagai salah satu sentra utama perikanan tangkap nasional dengan kontribusi produksi yang signifikan terhadap total produksi perikanan laut Indonesia [3]. Namun demikian, produksi perikanan tangkap bersifat dinamis dan menunjukkan fluktuasi yang cukup tinggi antarwilayah dan antarperiode waktu, sehingga menyulitkan proses analisis, perencanaan, dan pengambilan keputusan berbasis data [4].

Dari perspektif sistem dan data, produksi perikanan tangkap merupakan fenomena kompleks yang dipengaruhi oleh berbagai faktor lingkungan, operasional, dan sosial ekonomi yang saling berinteraksi secara non-linier [5]. Faktor lingkungan, khususnya kondisi cuaca dan iklim, memiliki peran penting karena secara langsung memengaruhi keselamatan, intensitas aktivitas penangkapan ikan, serta dinamika ekosistem perairan laut [6], [7]. Perubahan suhu, kelembapan, curah hujan, dan kecepatan angin dapat membatasi waktu operasional nelayan sekaligus memengaruhi distribusi dan ketersediaan sumber daya ikan [8].

Dalam banyak penelitian, parameter oseanografi laut seperti suhu permukaan laut dan konsentrasi

klorofil-a sering digunakan untuk menganalisis variasi hasil tangkapan ikan [9], [10]. Meskipun demikian, ketersediaan data oseanografi historis dengan resolusi spasial yang memadai pada tingkat kabupaten/kota masih relatif terbatas, khususnya di wilayah Indonesia [11]. Keterbatasan ini menjadi kendala utama dalam pengembangan model analitik dan prediktif yang membutuhkan data lingkungan laut yang kontinu dan konsisten [12].

Sebagai alternatif, indikator geofisika atmosfer darat seperti suhu udara, kelembapan, curah hujan, durasi penyinaran matahari, dan kecepatan angin relatif lebih tersedia, terdokumentasi dengan baik, serta memiliki kesinambungan temporal yang lebih panjang [6], [13]. Beberapa studi menunjukkan bahwa indikator atmosfer darat memiliki keterkaitan tidak langsung dengan dinamika perairan laut, terutama di wilayah pesisir, sehingga berpotensi digunakan sebagai proksi kondisi lingkungan dalam analisis produksi perikanan tangkap [8], [12].

Dari sudut pandang Teknik Informatika dan analisis data, pemodelan hubungan antara indikator atmosfer dan produksi perikanan tangkap menghadirkan tantangan tersendiri. Hubungan antarvariabel umumnya bersifat *non-linier*, multivariat, serta mengandung *noise* dan heterogenitas yang tinggi [14]. Pendekatan statistik linier konvensional sering kali kurang mampu merepresentasikan kompleksitas tersebut secara

memadai, sehingga mendorong penggunaan metode *machine learning* yang lebih fleksibel dan adaptif [15].

Algoritma berbasis pohon keputusan, khususnya *Random Forest*, banyak digunakan dalam pemodelan sistem lingkungan karena kemampuannya dalam menangkap hubungan *non-linier*, mengelola data multivariat, serta menghasilkan estimasi yang relatif stabil melalui mekanisme *ensemble learning* [16], [17]. Dalam konteks regresi, *Random Forest* dapat dipandang sebagai estimator *non-parametrik* yang tidak memerlukan asumsi bentuk fungsi tertentu, sehingga sesuai untuk memodelkan fenomena lingkungan yang kompleks dan tidak terstruktur dengan baik [18].

Meskipun sejumlah penelitian telah menerapkan *Random Forest* untuk analisis produksi perikanan tangkap, sebagian besar masih berfokus pada aspek prediksi semata atau menggunakan variabel oseanografi laut yang sulit diperoleh secara konsisten [14], [19]. Penelitian yang secara khusus menempatkan pemodelan produksi perikanan tangkap dalam kerangka regresi *non-linier* berbasis indikator atmosfer darat, serta mengkaji perilaku kesalahan dan kestabilan estimasi model pada skala kabupaten/kota di Provinsi Jawa Timur, masih relatif terbatas.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis hubungan regresi *non-linier* antara indikator geofisika atmosfer dan volume produksi perikanan tangkap laut di Provinsi Jawa Timur menggunakan pendekatan statistik berbasis *machine learning*. *Random Forest* digunakan sebagai estimator regresi *non-parametrik* utama dan dibandingkan dengan *Decision Tree* sebagai model dasar. Melalui pendekatan ini, penelitian diharapkan dapat memberikan kontribusi dalam pengembangan analisis data dan sistem informasi perikanan berbasis Teknik Informatika, khususnya dalam menghadapi keterbatasan data lingkungan laut dan kompleksitas sistem perikanan tangkap.

2. TINJAUAN PUSTAKA

Produksi perikanan tangkap laut dipengaruhi oleh berbagai faktor lingkungan yang bersifat dinamis dan saling berinteraksi. Kondisi cuaca dan iklim memiliki peran penting karena dapat memengaruhi distribusi sumber daya ikan, keselamatan aktivitas penangkapan, serta intensitas operasional nelayan [1], [2]. Fluktuasi produksi yang tinggi menunjukkan bahwa hubungan antara faktor lingkungan dan hasil tangkapan tidak bersifat linier sederhana, melainkan dipengaruhi oleh interaksi multivariat yang kompleks [3].

Dalam kajian perikanan, parameter oseanografi laut seperti suhu permukaan laut dan klorofil-a sering digunakan untuk menganalisis variasi hasil tangkapan ikan [4], [5]. Namun, keterbatasan ketersediaan data oseanografi historis dengan resolusi spasial yang memadai, khususnya pada skala kabupaten/kota, menjadi kendala dalam penerapan analisis berbasis data tersebut [6]. Oleh karena itu, indikator geofisika

atmosfer darat seperti suhu udara, kelembapan, curah hujan, durasi penyinaran matahari, dan kecepatan angin banyak dipertimbangkan sebagai proksi lingkungan alternatif yang lebih tersedia dan konsisten [2], [7].

Seiring dengan perkembangan Teknik Informatika dan komputasi data, metode *machine learning* semakin banyak digunakan untuk menganalisis sistem lingkungan yang kompleks, termasuk dalam bidang perikanan [8]. Pendekatan ini memiliki keunggulan dalam menangkap hubungan *non-linier* dan mengelola data multivariat yang mengandung noise dan heterogenitas tinggi, yang sering kali sulit dimodelkan dengan pendekatan statistik linier konvensional [9].

Salah satu metode *machine learning* yang banyak digunakan adalah *Random Forest*, yaitu algoritma *ensemble learning* berbasis pohon keputusan yang menggabungkan sejumlah model untuk menghasilkan estimasi yang lebih stabil [10]. Dalam konteks regresi, *Random Forest* dapat dipandang sebagai estimator *non-parametrik* yang tidak memerlukan asumsi bentuk fungsi tertentu dan relatif tahan terhadap overfitting [11]. Beberapa penelitian menunjukkan bahwa *Random Forest* memberikan performa yang lebih baik dibandingkan *Decision Tree* tunggal dalam analisis produksi perikanan berbasis variabel lingkungan [2], [12].

Berdasarkan kajian pustaka tersebut, pemodelan produksi perikanan tangkap menggunakan pendekatan regresi *non-linier* berbasis *ensemble learning* dengan memanfaatkan indikator geofisika atmosfer darat menjadi relevan untuk dikaji. Pendekatan ini tidak hanya berorientasi pada akurasi prediksi, tetapi juga pada kestabilan estimasi dan interpretasi statistik model dalam konteks aplikasi sistem informasi perikanan berbasis Teknik Informatika.

3. METODE PENELITIAN

3.1. Data dan Variabel Penelitian

Penelitian ini menggunakan data sekunder berupa data produksi perikanan tangkap laut dan indikator geofisika atmosfer darat di Provinsi Jawa Timur pada periode 2020–2023. Produksi perikanan tangkap dinyatakan dalam satuan ton per tahun dan digunakan sebagai variabel respon. Indikator atmosfer yang digunakan sebagai variabel prediktor meliputi suhu udara, kelembapan udara, curah hujan, durasi penyinaran matahari, dan kecepatan angin.

Secara matematis, hubungan antara variabel prediktor dan variabel respon dinyatakan sebagai pasangan data pengamatan yang dirumuskan pada persamaan 1:

$$\{(x_i, y_i)\}_{i=1}^n \quad (1)$$

Dengan $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$ merupakan vektor indikator atmosfer dan y_i merupakan volume produksi perikanan tangkap pada pengamatan ke- i .

3.2. Pra-pemrosesan dan Transformasi Data

Tahapan pra-pemrosesan dilakukan untuk memastikan kualitas data sebelum digunakan dalam pemodelan. Data yang mengandung nilai hilang ditangani menggunakan metode imputasi berbasis nilai statistik representatif agar struktur data tetap terjaga. Selanjutnya, seluruh variabel numerik dinormalisasi untuk menghindari dominasi skala tertentu dalam proses pembelajaran model.

Distribusi variabel respon menunjukkan pola menceng ke kanan dengan keberadaan nilai ekstrem. Untuk menstabilkan varians dan mengurangi pengaruh pencilan, dilakukan transformasi logaritmik pada variabel respon pada persamaan 2:

$$y_i^* = \log(y_i + 1) \quad (2)$$

Transformasi ini bertujuan meningkatkan kestabilan numerik dan kualitas estimasi fungsi regresi non-linier yang akan dibangun.

Dataset yang telah diproses kemudian dibagi menjadi data latih dan data uji dengan proporsi 80% dan 20%.

3.3. Formulasi Masalah Regresi Non-linier

Hubungan antara indikator atmosfer dan produksi perikanan tangkap dimodelkan sebagai permasalahan regresi non-linier multivariat, yang secara umum dapat pada persamaan 3:

$$y_i^* = f(x_i) + \varepsilon_i \quad (3)$$

Dengan $f(\cdot)$ merupakan fungsi regresi tak diketahui dan ε_i merupakan galat acak. Tujuan pemodelan adalah memperoleh fungsi aproksimasi $\hat{f}(\cdot)$ yang mampu meminimalkan kesalahan prediksi antara nilai aktual dan nilai estimasi.

Pendekatan regresi non-parametrik dipilih karena tidak mengasumsikan bentuk fungsi tertentu, sehingga lebih fleksibel dalam menangkap hubungan kompleks dan interaksi non-linier antarvariabel.

3.4. Random Forest sebagai Estimator Regresi Non-parametrik

Random Forest digunakan sebagai estimator regresi non-parametrik utama dalam penelitian ini. Metode ini membangun sejumlah pohon keputusan secara acak melalui proses bootstrap sampling dan pemilihan subset fitur secara acak pada setiap node.

Prediksi *Random Forest* untuk suatu pengamatan x dirumuskan pada persamaan 4 sebagai rata-rata prediksi dari seluruh pohon keputusan:

$$\hat{f}_{RF}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (4)$$

Dengan $T_b(x)$ merupakan prediksi pohon keputusan ke- b dan B adalah jumlah pohon dalam ensemble.

Dari sudut pandang statistik, mekanisme agregasi ini berfungsi untuk menurunkan varians estimator tanpa meningkatkan bias secara signifikan, sehingga menghasilkan prediksi yang lebih stabil pada data yang kompleks dan mengandung noise.

3.5. Decision Tree sebagai Model Pembanding

Sebagai pembanding, digunakan model *Decision Tree Regressor* yang membangun satu pohon keputusan tunggal. Model ini membagi ruang fitur menjadi beberapa wilayah $\{R_1, R_2, \dots, R_K\}$ dengan prediksi pada setiap wilayah diberikan oleh nilai rata-rata respon yang dituliskan pada persamaan 5:

$$\hat{f}_{DT}(x) = \sum_{k=1}^K \bar{y}_{R_k} \cdot I(x \in R_k) \quad (5)$$

Dengan $\bar{y}_{R_k}$ merupakan nilai rata-rata variabel respon pada wilayah R_k dan $I(\cdot)$ adalah fungsi indikator.

Model *Decision Tree* digunakan untuk mengevaluasi peningkatan performa yang diperoleh melalui pendekatan ensemble pada *Random Forest*.

3.6. Evaluasi Kinerja Model

Kinerja model dievaluasi menggunakan tiga metrik statistik utama, yaitu Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan koefisien determinasi.

MAE didefinisikan pada persamaan 6:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^* - \hat{y}_i^*| \quad (6)$$

RMSE dirumuskan pada persamaan 7:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i^* - \hat{y}_i^*)^2} \quad (7)$$

Sementara itu, koefisien determinasi digunakan untuk mengukur proporsi variasi data yang dapat dijelaskan pada persamaan 8:

$$R^2 = 1 - \frac{\sum (y_i^* - \hat{y}_i^*)^2}{\sum (y_i^* - \bar{y}_i^*)^2} \quad (8)$$

Kombinasi ketiga metrik ini digunakan untuk mengevaluasi akurasi prediksi, kestabilan estimasi, serta kemampuan model dalam merepresentasikan hubungan non-linier antara indikator atmosfer dan produksi perikanan tangkap.

4. HASIL DAN PEMBAHASAN

4.1. Statistik Deskriptif Data Penelitian

Analisis statistik deskriptif dilakukan sebagai tahap awal untuk memahami karakteristik data sebelum dilakukan pemodelan regresi non-linier.

Statistik deskriptif memberikan gambaran mengenai sebaran data, kecenderungan nilai pusat, serta tingkat variasi pada masing-masing variabel yang digunakan.


Tabel 1. Statistik deskriptif variabel penelitian

Keterangan	Produksi (Ton)	Suhu (°C)	Kelembapan (%)	Curah Hujan (mm)
Jumlah data	1.166	1.166	1.166	1.166
Rata-rata	791.99	26.74	81.86	7.70
Simpangan baku	2.04	2.65	3.59	2.91
Minimum	0.01	21.80	72.60	3.40
Maksimum	20.79	29.10	89.10	14.60

Berdasarkan Tabel 1, variabel produksi perikanan tangkap menunjukkan variasi yang relatif besar dibandingkan variabel atmosfer. Hal ini mengindikasikan bahwa produksi perikanan merupakan variabel dengan tingkat heterogenitas tinggi, yang dipengaruhi oleh kombinasi berbagai faktor lingkungan dan non-lingkungan. Kondisi ini memperkuat justifikasi penggunaan pendekatan regresi non-linier dan non-parametrik dibandingkan model linier sederhana.

4.2. Analisis Hubungan Awal Antarvariabel

Sebagai analisis pendahuluan, dilakukan evaluasi hubungan linier antarvariabel menggunakan matriks korelasi. Analisis ini tidak bertujuan untuk menarik kesimpulan kausal, melainkan untuk mengidentifikasi pola keterkaitan awal dan potensi multikolinearitas.




Gambar 1. Matriks korelasi variabel penelitian

Hasil visualisasi pada Gambar 1 menunjukkan bahwa hubungan linier antara indikator atmosfer dan produksi perikanan cenderung lemah hingga sedang. Tidak adanya korelasi linier yang dominan mengindikasikan bahwa hubungan antarvariabel bersifat kompleks dan kemungkinan besar melibatkan interaksi non-linier. Kondisi ini mendukung pemilihan *Random Forest* sebagai model regresi non-parametrik yang tidak bergantung pada asumsi hubungan linier.

4.3. Hasil Pemodelan Regresi Menggunakan *Random Forest*

Model *Random Forest* Regressor dilatih menggunakan data latih dan diuji pada data uji untuk mengevaluasi kemampuan generalisasi model. Hasil prediksi dibandingkan dengan nilai aktual untuk menilai kedekatan estimasi regresi terhadap data observasi.




Gambar 2. Perbandingan nilai aktual dan prediksi produksi perikanan (*Random Forest*)

Visualisasi pada Gambar 2 menunjukkan bahwa sebagian besar titik prediksi berada di sekitar garis diagonal, yang merepresentasikan kondisi prediksi ideal. Penyebaran titik yang relatif simetris di sekitar garis tersebut menunjukkan bahwa model *Random Forest* mampu menangkap pola umum hubungan antara indikator atmosfer dan produksi perikanan setelah transformasi logaritmik diterapkan pada variabel respon.

Dari perspektif statistik, pola ini mengindikasikan bahwa estimator regresi yang dibangun memiliki tingkat bias yang relatif rendah, meskipun masih terdapat variasi residual yang mencerminkan kompleksitas sistem perikanan tangkap.

4.4. Perbandingan dengan Model *Decision Tree*



Gambar 3. Perbandingan nilai aktual dan prediksi produksi perikanan (*Decision Tree*)

Sebagai pembandingan, dilakukan pemodelan menggunakan *Decision Tree* Regressor untuk mengevaluasi kontribusi pendekatan ensemble pada *Random Forest*.

Dibandingkan dengan *Random Forest*, hasil prediksi *Decision Tree* pada Gambar 3 menunjukkan

penyebaran titik yang lebih tidak teratur dan deviasi yang lebih besar dari garis diagonal. Hal ini mencerminkan sensitivitas tinggi *Decision Tree* terhadap variasi data latih, yang secara statistik berkaitan dengan varians estimator yang tinggi.

Temuan ini menegaskan bahwa mekanisme agregasi pada *Random Forest* berperan penting dalam menurunkan varians prediksi dan meningkatkan kestabilan estimasi regresi.

4.5. Evaluasi Kinerja Model

Evaluasi kuantitatif dilakukan menggunakan metrik MAE, RMSE, dan koefisien determinasi untuk membandingkan performa kedua model secara objektif.


Tabel 2. Perbandingan kinerja model regresi

Metrik	<i>Random Forest</i>	<i>Decision Tree</i>
MAE	1.29	1.31
RMSE	1.58	1.60
R^2	0.2384	0.2111

Berdasarkan Tabel 3, *Random Forest* menghasilkan nilai MAE dan RMSE yang lebih rendah dibandingkan *Decision Tree*. Secara statistik, hal ini menunjukkan bahwa rata-rata kesalahan absolut dan kesalahan kuadrat pada *Random Forest* lebih kecil, sehingga estimasi regresi lebih mendekati nilai aktual.

Nilai koefisien determinasi yang relatif moderat menunjukkan bahwa hanya sebagian variasi produksi perikanan yang dapat dijelaskan oleh indikator atmosfer. Namun, dalam konteks sistem lingkungan yang kompleks dan dipengaruhi oleh banyak faktor laten, nilai ini tetap mencerminkan kemampuan model dalam menangkap pola hubungan utama tanpa overfitting.

4.6. Analisis Kepentingan Fitur



Gambar 4. Kepentingan fitur pada model *Random Forest*

Random Forest menyediakan ukuran kepentingan fitur yang dapat digunakan untuk mengevaluasi kontribusi relatif masing-masing variabel prediktor terhadap model regresi.

Hasil analisis Gambar 4 menunjukkan bahwa suhu udara dan kelembapan memiliki kontribusi terbesar terhadap pembentukan fungsi regresi, diikuti oleh variabel curah hujan, durasi penyinaran matahari, dan kecepatan angin. Secara statistik, hasil ini dapat

diinterpretasikan sebagai indikasi bahwa variasi termal dan kelembapan atmosfer memiliki sensitivitas yang lebih tinggi terhadap perubahan produksi perikanan tangkap.

Temuan ini konsisten dengan mekanisme fisik di lapangan, di mana kondisi atmosfer memengaruhi kenyamanan operasional nelayan serta dinamika ekosistem perairan pesisir.

4.7. Pembahasan dalam Perspektif Statistik-Informatika

Secara keseluruhan, hasil penelitian menunjukkan bahwa pendekatan regresi non-linier berbasis *ensemble learning* mampu memberikan estimasi yang lebih stabil dibandingkan model pohon tunggal. Dari sudut pandang statistik, keunggulan *Random Forest* terletak pada kemampuannya menurunkan varians estimator melalui proses agregasi, sehingga lebih sesuai untuk data lingkungan yang heterogen dan mengandung noise.

Meskipun nilai koefisien determinasi belum tinggi, kestabilan nilai MAE dan RMSE menunjukkan bahwa model memiliki kemampuan generalisasi yang memadai untuk aplikasi sistem informasi perikanan. Hal ini menegaskan bahwa pendekatan statistik berbasis *machine learning* dapat dimanfaatkan secara efektif dalam ranah Teknik Informatika untuk menganalisis sistem nyata yang kompleks dengan keterbatasan data langsung.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa pemodelan regresi non-linier berbasis *ensemble learning* dapat digunakan secara efektif untuk menganalisis hubungan antara indikator geofisika atmosfer dan produksi perikanan tangkap laut pada tingkat kabupaten/kota di Provinsi Jawa Timur. Transformasi logaritmik pada variabel respon terbukti meningkatkan kestabilan estimasi dengan mengurangi pengaruh pencilon dan heterogenitas data, sehingga mendukung pembentukan fungsi regresi yang lebih representatif. Hasil evaluasi statistik menunjukkan bahwa *Random Forest* sebagai estimator regresi non-parametrik menghasilkan kesalahan prediksi yang lebih rendah dan lebih stabil dibandingkan *Decision Tree*, yang mengindikasikan keberhasilan mekanisme agregasi dalam menurunkan varians estimator pada data lingkungan yang kompleks. Meskipun nilai koefisien determinasi masih tergolong moderat, temuan ini mencerminkan karakter sistem perikanan tangkap yang dipengaruhi oleh banyak faktor laten di luar variabel atmosfer yang digunakan. Analisis kepentingan fitur mengindikasikan bahwa suhu udara dan kelembapan memiliki sensitivitas tertinggi terhadap variasi produksi perikanan, sehingga berpotensi dimanfaatkan sebagai indikator awal dalam sistem informasi dan pendukung keputusan berbasis data. Penelitian selanjutnya disarankan untuk mengintegrasikan variabel oseanografi laut, faktor sosial ekonomi nelayan, serta resolusi temporal yang lebih tinggi guna

meningkatkan kemampuan representasi model, sekaligus mengembangkan pendekatan statistik dan komputasional yang lebih adaptif untuk mendukung pengelolaan perikanan berbasis teknologi informasi.

DAFTAR PUSTAKA

- [1] W. Wirata *et al.*, “Development of a Deep Learning Based Price Prediction Model for Katsuwonus pelamis at Nizam Zachman Fishing Port Jakarta Indonesia,” *Thalassas*, vol. 41, no. 2, p. 69, Jun. 2025, doi: 10.1007/s41208-025-00822-6.
- [2] S. Nurfitri, A. T. Putri, and M. R. Putri, “Investigation of environmental factors impact on fish catch in East Java waters,” *Depik*, vol. 14, no. 2, pp. 218–225, 2025, doi: 10.13170/depik.14.2.44373.
- [3] G. R. Aida, R. W. Illahi, and T. D. Pramesthy, “Analisis of The Effect of Fisherman, Fishing Boat, and Fishery Ports on Catching Fisheries Production in East Java Province,” *Barakuda 45 J. Ilmu Perikan. dan Kelaut.*, vol. 5, no. 1, pp. 35–44, Apr. 2023, doi: 10.47685/barakuda45.v5i1.338.
- [4] S. Triharyuni, P. Aisyah, K. Kasim, H. Samhudi, D. Nugroho, and A. Fudholi, “Sustainable Fishing Yields of Commercial Fish in Jatibarang Reservoir, Indonesia,” *Int. J. Sustain. Dev. Plan.*, vol. 18, no. 9, pp. 2695–2701, Sep. 2023, doi: 10.18280/ijstdp.180908.
- [5] V. S. Rawat, G. Azhikodan, and K. Yokoyama, “Prediction of fish (*Coilia nasus*) catch using spatiotemporal environmental variables and *Random Forest* model in a highly turbid macrotidal estuary,” *Ecol. Inform.*, vol. 86, p. 103048, May 2025, doi: 10.1016/j.ecoinf.2025.103048.
- [6] R. W. Illahi, A. F. Syahputra, G. R. Aida, and C. N. Prajasti, “Pengaruh Perubahan Iklim Terhadap Produksi Perikanan Tangkap di Laut Jawa Timur Indonesia,” *J. Agrimanex Agribusiness, Rural Manag. Dev. Ext.*, vol. 3, no. 2, 2023, doi: 10.35706/agrimanex.v3i2.8684.
- [7] B. Kühn *et al.*, “*Machine learning* Applications for Fisheries—At Scales from Genomics to Ecosystems,” *Rev. Fish. Sci. Aquac.*, vol. 33, no. 2, pp. 334–357, 2025, doi: 10.1080/23308249.2024.2423189.
- [8] X. Fu *et al.*, “Simulation and forecasting of fishery weather based on statistical *machine learning*,” *Inf. Process. Agric.*, vol. 11, no. 1, pp. 127–142, 2024, doi: 10.1016/j.inpa.2023.05.001.
- [9] S. J. Hasan, M. M. Haque, M. Aktaruzzaman, M. M. N. A. Kabir, and M. S. Bin Aziz, “Relationship Between Marine Fish Production and Climatic and Oceanographic Factors: Evidence From the Bay of Bengal, Bangladesh,” *Aquac. Fish Fish.*, vol. 5, no. 2, pp. 1–17, 2025, doi: 10.1002/aff2.70049.
- [10] S. Asuhadi, M. Zainuddin, S. Safruddin, and M. Musbir, “Spatial Modeling of Yellowfin Tuna in the Banda Sea Based on Oceanographic Factors Using MaxEnt,” *J. Indones. Trop. Anim. Agric.*, vol. 30, no. 1, pp. 103–114, Mar. 2025, doi: 10.14710/ik.ijms.30.1.103-114.
- [11] M. D. Setiawati, H. A. Rachman, A. R. Asyaktur, R. Y. Setiawan, A. Syahailatua, and S. Wouthuyzen, “The habitat preference of commercial tuna species based on a daily environmental database approach in the tropical region of the Eastern Indian Ocean off Java-Bali waters,” *Deep. Res. Part II Top. Stud. Oceanogr.*, vol. 216, p. 105400, Aug. 2024, doi: 10.1016/j.dsr2.2024.105400.
- [12] A. Sudradjat, B. S. Muntalif, N. Marasabessy, F. Mulyadi, and M. I. Firdaus, “Relationship between chlorophyll-a, rainfall, and climate phenomena in tropical archipelagic estuarine waters,” *Heliyon*, vol. 10, no. 4, p. e25812, 2024, doi: 10.1016/j.heliyon.2024.e25812.
- [13] V. S. Aswal, B. K. Singh, and R. Maheshwari, “*Machine learning*-based model for prediction of concrete strength,” *Multiscale Multidiscip. Model. Exp. Des.*, vol. 8, no. 1, p. 48, Jan. 2025, doi: 10.1007/s41939-024-00609-x.
- [14] G. A. Pradana, “A Study of Prediction Model for Capture Fisheries Production in Indonesian Sea Waters Using *Machine learning*,” *JISA(Jurnal Inform. dan Sains)*, vol. 6, no. 1, pp. 17–23, 2023, doi: 10.31326/jisa.v6i1.1553.
- [15] Alfira Yuniar, Mukti Zainuddin, Safruddin, Muzzneena Ahmad Mustapha, Rachmat Hidayat, and Siti Khadijah Srioktoviana, “Ecological Modelling of Potential Habitats for Indian Mackerel (*Rastrelliger spp.*) in the Western of Banda Sea using an Artificial Neural Network Approach,” *Trop. Life Sci. Res.*, vol. 36, no. 3, pp. 177–196, Oct. 2025, doi: 10.21315/tlsr2025.36.3.9.
- [16] I. Fatika, L. Fathiyaturrahmi, E. Sutanta, C. Iswahyudi, and R. Widiastuti, “Early Warning System for Local Government Financial Distress Using Support Vector Machine with Synthetic Tabular Data,” 2025, pp. 48–66. doi: 10.2991/978-94-6463-956-8_6.
- [17] W. Yang, Y. Ji, X. Meng, S. Gong, and S. Zhou, “Hybrid data-driven estimation for compressive strength of eco-friendly geopolymer concrete containing corncob ash,” *J. Comput. Methods Sci. Eng.*, Sep. 2025, doi: 10.1177/14727978251385192.
- [18] W. Yang, Y. Ji, S. Zhou, L. Ji, Y. Lei, and M. Wang, “Towards Sustainable Construction: Hybrid Prediction Modeling for Compressive Strength of Rice Husk Ash Concrete,” *Designs*, vol. 9, no. 6, p. 141, Dec. 2025, doi: 10.3390/designs9060141.
- [19] A. N. Maimanah, Wahyono, and F. Makhrus, “Acne Classification with Gaussian Mixture Model based on Texture Features,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 8, pp. 363–369, 2022, doi: 10.14569/IJACSA.2022.0130844.