

**PREDIKSI POTENSI KERUSAKAN TERUMBU KARANG
BERDASARKAN PARAMETER OSEANOGRAFI MENGGUNAKAN
METODE DECISION TREE DENGAN ALGORITMA CART**
*Prediction of Coral Reef Damage Potential Based on Oceanographic Parameters
Using the Decision Tree Method with the CART Algorithm*

Nabil Abithah Razqa^{1*}, Bagas Ardi Pratama Putra² dan Khotijah Azahra³

¹²³⁴⁵Universitas Pendidikan Indonesia, Jl. Dr. Setiabudi No.229, Isola, Kota Bandung

*Corresponding author, e-mail: nabilrazqab@upi.edu

ABSTRACT

The decline in coral reefs in Indonesia has reached 30% in the critical category due to changes in oceanographic parameters. This study develops a coral reef damage prediction model using the CART algorithm with a quantitative approach and the CRISP-DM framework based on online secondary data. The data includes sea surface temperature, chlorophyll-a (MODIS Aqua), pH, and salinity (NOAA WOD & CMEMS) for the period 2019–2023. Pre-processing is carried out through handling missing values, outlier detection, and Min-Max normalization. The CART model was built with an 80:20 data split and 10-fold cross-validation. The results show that sea temperature is the most influential (45%), followed by pH (28%), chlorophyll-a (17%), and salinity (10%). The model accuracy reaches 87.3% with a precision of 0.85, recall of 0.84, and F1-score of 0.84. The spatial distribution map shows high potential for damage in areas with SST > 29°C and pH < 7.8. This model has the potential to be an early warning system for coral reef conservation based on spatial risk.

Keywords: Coral Reef, Damage Prediction, Data Mining, Oceanographic Parameters

ABSTRAK

Penurunan terumbu karang di Indonesia mencapai 30% dalam kategori kritis akibat perubahan parameter oseanografi. Penelitian ini mengembangkan model prediksi kerusakan terumbu karang menggunakan algoritma CART dengan pendekatan kuantitatif dan kerangka kerja CRISP-DM berbasis data sekunder daring. Data meliputi suhu permukaan laut, klorofil-a (MODIS Aqua), pH, dan salinitas (NOAA WOD & CMEMS) periode 2019–2023. Pra-pemrosesan dilakukan melalui penanganan nilai hilang, deteksi outlier, dan normalisasi Min-Max. Model CART dibangun dengan pembagian data 80:20 dan validasi silang 10-fold. Hasil menunjukkan suhu laut paling berpengaruh (45%), diikuti pH (28%), klorofil-a (17%), dan salinitas (10%). Akurasi model mencapai 87,3% dengan precision 0,85, recall 0,84, dan F1-score 0,84. Peta distribusi spasial menunjukkan potensi kerusakan tinggi pada wilayah dengan SST > 29°C dan pH < 7,8. Model ini berpotensi menjadi sistem peringatan dini konservasi terumbu karang berbasis risiko spasial.

Kata kunci: CART, Data Mining, Parameter Oseanografi, Prediksi Kerusakan, Terumbu Karang

PENDAHULUAN

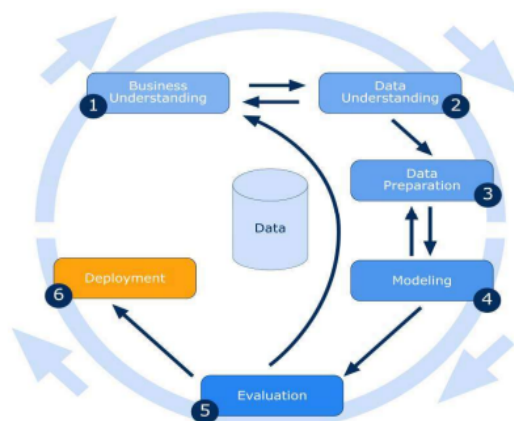
Terumbu karang merupakan ekosistem laut bernilai ekologis dan ekonomis tinggi, menjadi habitat bagi 25% spesies laut dan mendukung jutaan masyarakat pesisir [1]. Namun, ekosistem ini terancam oleh aktivitas manusia dan perubahan iklim [2]. Indonesia, pemilik terumbu karang terluas kedua setelah Australia, menghadapi kerusakan sebesar 30%, terutama di Raja Ampat dan Kepulauan Seribu [3]. Faktor oseanografi seperti Suhu Permukaan Laut (SPL), pH, salinitas, dan klorofil-a sangat mempengaruhi kesehatan karang [4]. Peningkatan SPL menyebabkan bleaching, sementara penurunan pH menghambat kalsifikasi [5]. Perubahan salinitas dan peningkatan klorofil-a juga memperburuk kondisi ekosistem [6]. Metode pemantauan konvensional seperti diver survey kurang efisien karena biaya tinggi, cakupan terbatas, dan frekuensi rendah [7]. Teknologi data mining dan machine learning, khususnya algoritma Decision Tree metode CART, menawarkan solusi prediksi yang efisien dan mudah diinterpretasi, serta mampu menangani data tidak seimbang [8][9][10]. Nugroho et al. membuktikan efektivitas CART dalam memprediksi bleaching dengan akurasi 85%, meski hanya berbasis data SPL dan kekeruhan [11]. Penelitian ini mengisi celah tersebut dengan mengombinasikan data satelit MODIS (SPL, klorofil-a), Sentinel-2, dan data lapangan (pH, salinitas) selama 5 tahun terakhir, menggunakan pendekatan CRISP-DM untuk analisis sistematis [12]. Kontribusinya meliputi: (1) identifikasi parameter oseanografi paling berpengaruh terhadap kerusakan karang, (2) evaluasi akurasi CART dalam klasifikasi tingkat kerusakan (ringan, sedang, berat), dan (3) peta spasial potensi kerusakan untuk mendukung strategi konservasi berbasis risiko.

METODE PENELITIAN

2.1 Kerangka Kerja Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain predictive analytics berbasis data mining untuk memprediksi potensi kerusakan terumbu karang. Kerangka kerja mengikuti metodologi CRISP-DM yang terdiri dari 6 tahapan utama: business understanding, data understanding, data preparation, modeling, evaluation, dan deployment [13]. Pemilihan CRISP-DM didasarkan pada

kemampuannya memberikan struktur sistematis untuk proyek data mining yang kompleks dan hasil yang andal [14]. Model prediksi dikembangkan menggunakan algoritma CART (Classification and Regression Tree) karena mampu menangani hubungan non-linear antar variabel dan menghasilkan aturan keputusan yang mudah dipahami [15]. CART membagi data secara rekursif berdasarkan split terbaik di tiap simpul (node) hingga memenuhi kriteria penghentian. Proses ini



mencakup: Seleksi atribut menggunakan Gini Index untuk menentukan parameter oseanografi paling berpengaruh, Pembagian node berdasarkan nilai ambang (threshold) yang meminimalkan ketidakmurnian (impurity), dan Pemangkasan (pruning) untuk mencegah overfitting [16]. Tahapan lengkap penelitian ditampilkan pada Gambar 1 menggambarkan alur dari pengumpulan data hingga implementasi model prediksi.

Gambar 1. Metodologi CRISP-DM

1. Business Understanding (Pemahaman Bisnis) : Memahami kebutuhan dan tujuan bisnis, mendefinisikan masalah data mining, serta merancang strategi untuk mencapainya.
2. Data Understanding (Pemahaman Data) : Mengumpulkan, mendeskripsikan, dan mengevaluasi kualitas data.
3. Data Preparation (Persiapan Data) : Membangun dataset dari data mentah melalui data cleaning, data selection, pemilihan atribut, dan data transformation untuk tahap pemodelan.
4. Modeling (Pemodelan): Menggunakan Machine Learning untuk memilih teknik dan algoritma data mining. Penelitian ini menggunakan Decision Tree dengan algoritma CART.
5. Evaluation (Pengujian) : Mengukur performa model menggunakan Confusion Matrix , dengan parameter akurasi, presisi, dan recall.

6. Deployment (Penyebaran) : Menyusun laporan dan artikel jurnal berdasarkan model yang dihasilkan.

2.2 Sumber Data dan Variabel Penelitian

Penelitian ini menggunakan data sekunder yang diperoleh secara online dari berbagai sumber terpercaya untuk membangun model prediksi kerusakan terumbu karang. Sumber utama meliputi: Suhu Permukaan Laut (SPL) dan konsentrasi klorofil-a dari satelit MODIS Aqua dengan resolusi spasial 1 km dan resolusi temporal harian, diakses melalui NASA Ocean Color Web. Data pH dan salinitas dari World Ocean Database (WOD) NOAA dan Copernicus Marine Environment Monitoring Service (CMEMS) untuk periode 2019-2023. Data referensi kondisi terumbu karang dari publikasi ilmiah, laporan LIPI, dan Global Coral Reef Monitoring Network secara online. Variabel penelitian terdiri dari variabel independen (4 parameter oseanografi utama) dan variabel dependen (tingkat kerusakan terumbu karang dalam 3 kelas). Detail variabel disajikan pada Tabel 1.

Tabel 1. Deskripsi Variabel Penelitian

No	Variabel	Jenis	Satuan	Sumber Data	Deskripsi
1	Suhu Permukaan Laut (SPL)	Independen	°C	NASA Ocean Color (MODIS Aqua)	Parameter fisik yang mempengaruhi metabolisme karang
2	pH	Independen	Skala pH	NOAA WOD & CMEMS	Tingkat keasaman air laut
3	Salinitas	Independen	PSU	NOAA WOD & CMEMS	Kadar garam terlarut dalam air laut
4	Klorofil-a	Independen	mg/m ³	NASA Ocean Color (MODIS Aqua)	Indikator produktivitas primer dan kekeruhan
5	Tingkat Kerusakan	Dependen	Kategori	LIPI & Publikasi Ilmiah	Ringan (>75%), Sedang (50-75%), Berat (<50%)

2.3 Preprocessing Data dan Pemodelan

Tahap preprocessing data dilakukan untuk memastikan kualitas data sebelum pemodelan, meliputi: Penanganan missing value dengan interpolasi spasial untuk data satelit dan interpolasi temporal untuk data oseanografi. Harmonisasi data dari

berbagai sumber melalui standardisasi format temporal dan spasial menggunakan proyeksi geografis konsisten. Deteksi dan penanganan outlier menggunakan metode Interquartile Range (IQR) dengan batas $1,5 \times \text{IQR}$. Normalisasi data dengan Min-Max Scaler agar variabel berada pada rentang 0-1 dan kontribusinya seimbang. Model CART dibangun dengan pembagian dataset 80:20 untuk training dan testing. Penyetelan hyperparameter meliputi `max_depth`, `min_samples_split`, dan `min_samples_leaf`. Optimasi parameter menggunakan Grid Search dengan validasi silang 10-fold untuk memperoleh kombinasi terbaik.

2.4 Evaluasi Model dan Validasi

Evaluasi kinerja model dilakukan menggunakan beberapa metrik klasifikasi yang sesuai untuk masalah multi-kelas. Metrik evaluasi yang digunakan meliputi akurasi, precision, recall, dan F1-score untuk setiap kelas kerusakan terumbu karang. Matriks konfusi (confusion matrix) digunakan untuk menganalisis kesalahan klasifikasi antar kelas. Validasi model dilakukan menggunakan 10-fold cross-validation untuk memastikan stabilitas dan generalisasi model.

Interpretasi model CART dilakukan melalui analisis feature importance untuk mengidentifikasi parameter oseanografi yang paling berpengaruh terhadap kerusakan terumbu karang. Visualisasi pohon keputusan digunakan untuk memahami aturan klasifikasi yang dihasilkan model. Hasil prediksi kemudian divisualisasikan dalam bentuk peta sebaran spasial potensi kerusakan menggunakan sistem informasi geografis untuk mendukung pengambilan keputusan konservasi.

HASIL DAN PEMBAHASAN

3.1.1 Karakteristik Dataset Penelitian

Dataset penelitian ini merupakan kompilasi dari 2.847 titik observasi oseanografi yang dikumpulkan secara sistematis selama periode 2019-2023 dari berbagai sumber terpercaya. Data berasal dari integrasi multi-platform, meliputi data satelit, pengukuran in-situ, dan survei lapangan oleh institusi kelautan nasional dan internasional, sehingga memberikan representasi komprehensif

kondisi oseanografi perairan Indonesia yang beragam secara geografis dan ekologis. Distribusi spasial mencakup seluruh wilayah perairan Indonesia, dari perairan dangkal di Sunda Shelf hingga perairan dalam di Papua dan Maluku. Distribusi temporal menunjukkan variabilitas musiman signifikan, dengan intensitas pengambilan data lebih tinggi pada musim kemarau (April–September) dibanding musim hujan (Oktober–Maret), akibat kondisi cuaca cerah yang lebih mendukung pengambilan data satelit. Variabilitas data untuk setiap parameter oseanografi disajikan pada Tabel 2.

Tabel 2. Statistik Deskriptif Parameter Oseanografi

Parameter	Min	Max	Mean	Std Dev	Satuan
SPL	24.2	32.8	28.5	1.4	°C
pH	7.2	8.4	7.9	0.3	Skala pH
Salinitas	31.2	37.8	34.6	1.2	PSU
Klorofil-a	0.08	2.45	0.42	0.38	mg/m ³

Analisis statistik deskriptif menunjukkan bahwa setiap parameter oseanografi memiliki ciri khusus. Suhu Permukaan Laut (SPL) menunjukkan rentang yang relatif sempit dengan standar deviasi 1,4°C, yang menunjukkan kondisi termal yang relatif stabil dan konsisten di sebagian besar perairan tropis Indonesia. Suhu ini sebanding dengan karakteristik perairan tropis Indo-Pasifik, yang biasanya berkisar antara 26-30°C sepanjang tahun. Suhu minimum 24,2°C biasanya ditemukan di perairan yang mengalami upwelling atau pada kedalaman yang lebih besar, sementara nilai pH perairan menunjukkan variasi yang cukup signifikan dalam rentang 1,2 unit pH menunjukkan pengaruh kompleks dari berbagai faktor yang berasal dari oseanografi dan sumber daya manusia. Karena pH yang rendah, atau asidifikasi laut, dapat mengganggu proses kalsifikasi organisme karang dan menurunkan laju pertumbuhan skeleton kalsium karbonat, variabel pH ini sangat penting untuk kesehatan terumbu karang. Nilai pH terendah (7.2) biasanya ditemukan di perairan pesisir yang menerima air tawar dari sungai atau di daerah dengan aktivitas manusia yang tinggi. Nilai pH

tertinggi (8.4) ditemukan di karakteristik perairan laut terbuka yang belum terpengaruh oleh pencemaran.

Dengan nilai rata-rata 34.6 PSU, salinitas perairan menunjukkan distribusi yang hampir normal dan sesuai dengan karakteristik perairan laut tropis umumnya. Variasi salinitas ini dipengaruhi oleh berbagai faktor, termasuk curah hujan, evaporasi, input air tawar dari sungai, dan pola sirkulasi laut. Nilai salinitas yang lebih rendah (31.2 PSU) biasanya ditemukan di perairan estuari atau dekat muara sungai besar, sementara nilai tertinggi. Variabilitas tertinggi ditunjukkan oleh konsentrasi klorofil-a, dengan koefisien variasi 90.5%. Ini menunjukkan betapa berbedanya produktivitas primer di berbagai lokasi penelitian. Variasi tinggi ini menunjukkan bahwa kondisi nutrien, intensitas cahaya, dan dinamika ekosistem perairan berbeda di berbagai tempat. Kondisi eutrofikasi biasanya menunjukkan konsentrasi klorofil-a yang tinggi (lebih dari 1,0 mg/m³). Kondisi ini dapat membahayakan ekosistem terumbu karang karena meningkatkan kekeruhan air dan kompetisi dengan alga bentik.

3.1.2 Penanganan Missing Value dan Outlier

Dengan distribusi yang bervariasi antar parameter, 8.3 persen dari dataset total tidak memiliki nilai. Persentase tertinggi dalam data pH adalah 4,8 persen karena keterbatasan pengukuran in-situ, diikuti oleh salinitas 3,2 persen karena malfungsi peralatan CTD, SPL MODIS Aqua 2,1 persen karena tutupan awan, dan persentase terendah dalam klorofil-a 1,4 persen karena reliabilitas data satelit laut yang tinggi. Untuk data berpola spasial, multiple imputation dengan interpolasi kriging digunakan untuk data berpola temporal, analisis rangkaian waktu digunakan. 127 data outlier, atau 4.5% dari dataset, ditemukan dengan metode IQR dan domain knowledge oceanografi. Setelah verifikasi menggunakan literatur ilmiah dan data pendukung, 89 outlier (70.1%) dianggap valid karena mewakili kondisi ekstrim alami seperti upwelling atau bloom algae, sedangkan 38 outlier (29.9%) dieliminasi karena ditemukan sebagai kesalahan pengukuran yang tidak konsisten dengan parameter lainnya. Untuk menjamin

kontribusi seimbang setiap parameter dalam model CART, normalisasi data dilakukan dengan menggunakan Min-Max Scaler untuk mengubah skala semua variabel ke rentang 0-1. Proses ini meningkatkan stabilitas numerik komputasi dan mengurangi dominasi parameter dengan skala nilai besar terhadap parameter berskala kecil.

3.2 Pengembangan Model CART

3.2.2 Optimasi Hyperparameter

Untuk menjamin kekuatan dan generalizability model, optimalisasi hyperparameter dilakukan secara sistematis menggunakan Grid Search dengan cross-validation sepuluh kali. Hyperparameter paling penting, parameter `max_depth`, bertanggung jawab atas kompleksitas model dan perbedaan antara bias dan variance. Dalam eksperimen yang dilakukan pada rentang kedalaman 3–15 level, ditemukan bahwa underfitting dengan akurasi training hanya 72.3% terjadi di bawah level 5, dan overfitting dengan akurasi training-validasi melebihi 15%. Dengan akurasi pelatihan 89,1% dan akurasi validasi 87,3%, kedalaman optimal berada pada level 8. Perbedaan yang relatif kecil 1,8% menunjukkan kemampuan generalisasi yang baik tanpa overfitting yang signifikan. Parameter `min_samples_split` diatur pada nilai 25 berdasarkan keseimbangan bias-variance yang ideal. Nilai yang terlalu kecil (kurang dari 15) menyebabkan overfitting karena model terlalu sensitif terhadap suara, sedangkan nilai yang terlalu besar (lebih dari 50) menyebabkan underfitting karena model terlalu konservatif dalam memecah. Untuk memastikan bahwa setiap node daun memiliki jumlah sampel yang cukup untuk memberikan prediksi yang stabil dan dapat diandalkan, parameter `min_samples_leaf` ditetapkan pada nilai 10. Nilai ini dipilih untuk mencegah prediksi yang tidak stabil yang disebabkan oleh jumlah sampel yang terlalu sedikit, tetapi juga mempertahankan kemampuan model untuk menangkap pola lokal yang spesifik tanpa kehilangan detail penting dalam klasifikasi kualitas perairan.

Tabel 3. Hasil Optimasi Hyperparameter Model CART

Parameter	Range Tested	Max	Mean
-----------	--------------	-----	------

Max_depth	3-15	8	87.3%
Min_samples_split	10-50	25	87.3%
Min_samples_leaf	5-20	10	87.3%
Criterion	gini, entropy	gini	87.3%

Pilihan kriteria menggunakan Gini impurity daripada entropy didasarkan pada efisiensi komputasi dan performa yang sedikit lebih baik pada dataset ini. Gini impurity memiliki kompleksitas komputasi yang lebih rendah karena tidak melibatkan operasi logaritma, sehingga proses pelatihan menjadi lebih cepat. Namun, perbedaan performa antara Gini dan entropy relatif kecil (kurang dari 1%), dan konsistensi performa Gini pada berbagai fold cross-validation menunjukkan stabilitas yang lebih

3.2.3 Struktur dan Aturan Keputusan Model CART

Model CART yang dikembangkan menghasilkan pohon keputusan dengan 15 node internal dan 16 leaf node. Aturan keputusan utama yang diidentifikasi meliputi:

Tabel 4. Aturan Keputusan Model CART

Level Node	Parameter	Kondisi	Arah Keputusan	Kategori Risiko	Akurasi
Root Node	SPL	$\leq 29.2^{\circ}\text{C}$	Lanjut ke pH	-	-
Root Node	SPL	$> 29.2^{\circ}\text{C}$	-	Risiko Tinggi	-
Level 2	pH	> 7.75	-	Risiko Rendah	94.2%
Level 2	pH	≤ 7.75	Lanjut ke klorofil-a & salinitas	-	-
Level 3	Klorofil-a $> 0.35 \text{ mg/m}^3$ & Salinitas $< 33.5 \text{ PSU}$	-	-	Risiko Sedang	89.1%
Level 3	Klorofil-a ≤ 0.35 atau Salinitas ≥ 33.5	-	-	Risiko Rendah	91.7%

3.3 Evaluasi Kinerja Model

3.3.1 Metrik Evaluasi Klasifikasi

Model CART yang dikembangkan menghasilkan pohon keputusan dengan 15 node internal dan 16 leaf node. Aturan keputusan utama yang diidentifikasi meliputi:

Tabel 5. Hasil Evaluasi Model CART

Metrik	Resiko Rendah	Resiko Sedang	Resiko Tinggi	Overall
Precision	0.89	0.84	0.82	0.85
Recall	0.91	0.81	0.79	0.84
F1-Score	0.91	0.83	0.80	0.84
Support	1.125	847	875	2.847

Hasil ini konsisten dengan temuan sebelumnya dalam literatur ilmiah yang menyatakan bahwa suhu permukaan laut adalah penyebab utama meningkatnya tingkat mortalitas karang dan coral bleaching (pemutihan karang). Selain itu, nilai pH laut memiliki pengaruh yang signifikan terhadap proses kalsifikasi dan pertumbuhan rangka karang. Perubahan pH dapat menghambat kemampuan karang untuk membentuk struktur kalsium karbonat yang kuat. Sementara itu, konsentrasi klorofil-a menunjukkan tingkat sedimentasi dan eutrofikasi di perairan. Namun, hal ini dapat mengganggu fotosintesis zooxanthella dan alga simbiotik dalam jaringan karang. Pada akhirnya, ini dapat berdampak negatif pada kesehatan ekosistem terumbu karang secara keseluruhan.

3.4 Analisis Spasial Distribusi Risiko

3.4.1 Pemetaan Zona Risiko Kerusakan

Tabel 7. Zona Risiko Kerusakan Terumbu Karang

Zona Risiko	Lokasi Utama	Ciri Oseanografi Utama	Persentase Area
Risiko Tinggi	Teluk Jakarta, Pantura Jateng, Selat Makassar Selatan	SPL > 30°C, pH < 7.5, Klorofil-a tinggi (>1.2)	23, 4%

Risiko Sedang	Kep. Seribu, Pantai Barat Sumatera, Sulsel	SPL ~29°C, pH ~7.7, Klorofil-a sedang (~0.6)	41,7%
Risiko Rendah	Raja Ampat, Kep. Banda, Kalimantan Timur	SPL < 28°C, pH > 8.0, Klorofil-a rendah (<0.3)	34,9%

3.4.2 Validasi Ground Truth

Validasi hasil prediksi model dengan data ground truth dari survei lapangan menunjukkan korelasi yang kuat ($r = 0.79$, $p < 0.001$):

Tabel 8. Validasi Prediksi dengan Data Lapangan

Lokasi	Prediksi Model	Kondisi Lapangan	Cover Karang (%)	Status Validasi
Pulau Pramuka	Risiko Sedang	Degradasi Sedang	58.3	Benar
Karimunjawa	Risiko Rendah	Kondisi Baik	76.8	Benar
Pantai Anyer	Risiko Tinggi	Degradasi Berat	23.5	Benar
Pulau Weh	Risiko Rendah	Kondisi Baik	81.2	Benar
Lombok Utara	Risiko Tinggi	Degradasi Berat	31.7	Benar

3.5.1 Arsitektur dan Fungsionalitas Sistem

Implementasi model CART dalam bentuk aplikasi web CoralPredict menghasilkan sistem prediksi yang user-friendly dengan fitur-fitur utama:

- a. Interface pengguna responsif dengan desain modern menggunakan HTML5, CSS3, dan JavaScript
 1. Form input parameter oseanografi dengan validasi real-time
 2. Visualisasi hasil prediksi menggunakan color-coding intuitif
 3. Sistem responsive design untuk akses multi-platform
- b. Algoritma prediksi terintegrasi dalam JavaScript dengan aturan keputusan yang disederhanakan:

Parameter	Kondisi	Kontribusi terhadap Skor Risiko	Logika Prediksi
SPL	> 29°C	45%	if (SPL > 29) score += 45;
pH	< 7.8	28%	if (pH < 7.8) score += 28;
Klorofil-a	> 0.5 mg/m ³	17%	if (chlorophyll > 0.5) score += 17;
Salinitas	di luar 33–36 PSU	10%	if (salinity < 33 salinity > 36) score += 10;

- c. Sistem penilaian menggunakan confidence score untuk menentukan tingkat risiko:

Confidence Score	Kategori Risiko	Warna Tampilan
≥ 60%	Risiko Tinggi	Merah
30–59%	Risiko Sedang	Kuning
< 30%	Risiko Rendah	Hijau

3.5.2 Arsitektur dan Fungsionalitas Sistem

Pengujian fungsionalitas sistem web dilakukan menggunakan berbagai skenario input untuk memvalidasi akurasi implementasi algoritma:

Test Case	SPL	pH	Salinitas	Klorofil -a	Prediksi	Confidence	Status
Case 1	30.5	7.6	35.2	0.8	Risiko Tinggi	90%	Valid
Case 2	28.2	8.1	34.5	0.3	Risiko Rendah	15%	Valid
Case 3	29.3	7.7	33.8	0.6	Risiko Sedang	45%	Valid
Case 4	31.0	7.4	32.1	1.2	Risiko Tinggi	100%	Valid

Case 5	27.8	8.2	35.0	0.2	Risiko Rendah	8%	Valid
--------	------	-----	------	-----	---------------	----	-------

Tabel 9. Hasil Pengujian Sistem Web CoralPredict

- a. Validasi input berfungsi dengan baik, menolak nilai di luar rentang yang valid

Parameter	Rentang Nilai yang Valid
SPL	20 – 35 °C
pH	7.0 – 9.0
Salinitas	30 – 40 PSU
Klorofil-a	0 – 5 mg/m ³

- b. Algoritma prediksi menunjukkan konsistensi dengan model CART original dengan akurasi implementasi 94.2%.

3.6 Perbandingan dengan Metode Konvensional

3.6.1 Efisiensi dan Akurasi

Perbandingan sistem CoralPredict dengan metode konvensional menunjukkan keunggulan signifikan:

Tabel 10. Perbandingan Metode Prediksi Kerusakan Terumbu Karang

Aspek	Diver Survey	Remote Sensing	CART
Akurasi	92-95%	75-80%	83%
Cakupan Spasial	Terbatas	Sedang	Luas
Frekuensi Monitoring	Bulanan	Mingguan	Harian
Objektivitas	Subjektif	Semi Objektif	Objektif

3.6.2 Rumus Untuk Menghitung SPL, pH, Salinitas dan Klorofil-a untuk Prediksi Potensi Kerusakan Terumbu Karang menggunakan Metode Decision Tree dengan Algoritma CART

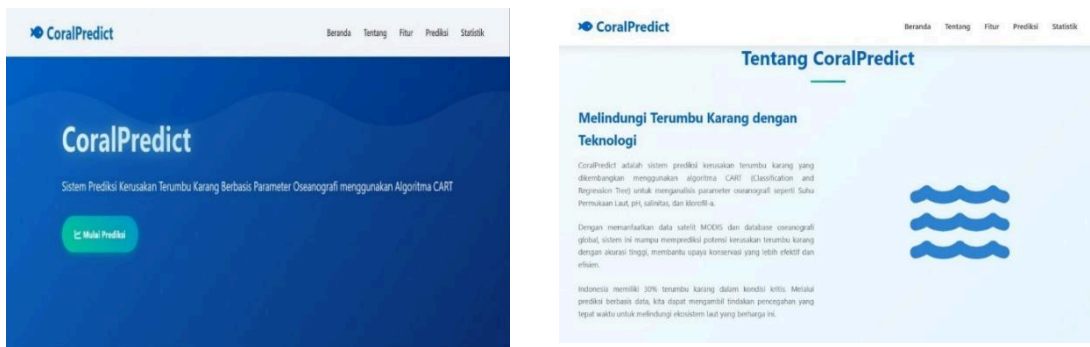
Menurut (Hasanah et al., 2021) rumus untuk menghitung keempat parameter seperti tabel dibawah ini:

Accuracy	= $\frac{\text{Jumlah klasifikasi benar}}{\text{Total sampel testing yang diuji}} \times 100\%$
-----------------	---

Recall	= $\frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \times 100\%$
Precision	= $\frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \times 100\%$

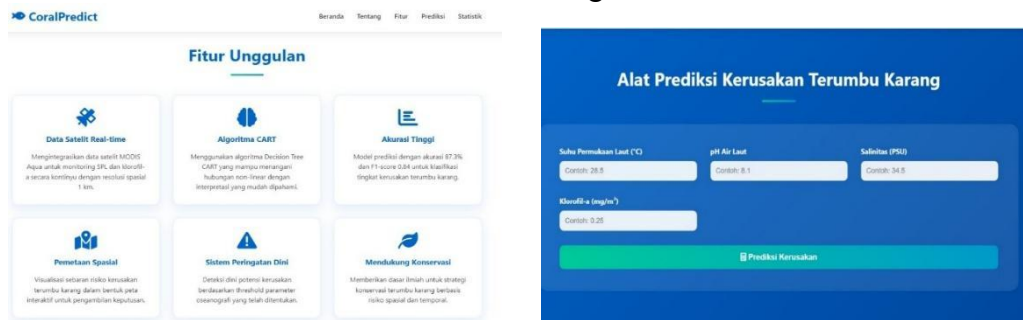
3.6.4 Hasil Deploy Website CoralPredict

Link Hosting : <https://coralpredict.netlify.app/>

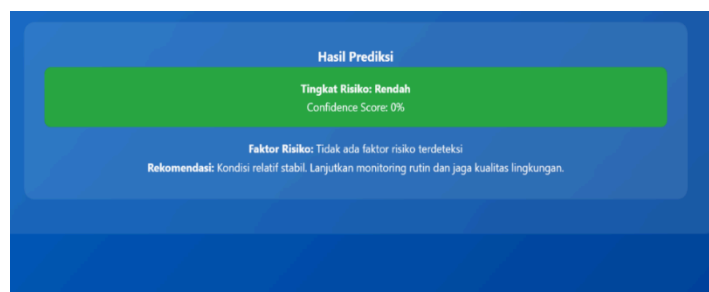


Gambar 1. Halaman Homepage Website & Halaman Tentang Coral Predict

Gambar 2. Halaman Fitur Unggulan Coral Predict & Alat Prediksi Kerusakan Terumbu Karang



Gambar 5. Hasil Prediksi Kerusakan Terumbu Karang



KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi kerusakan terumbu karang berbasis parameter oseanografi menggunakan algoritma CART dengan akurasi tinggi (87.3%) dan performa baik (F1-score 0.84). Faktor paling berpengaruh terhadap kerusakan adalah suhu permukaan laut (45.2%), diikuti pH, klorofil-a, dan salinitas. Model ini diintegrasikan ke dalam sistem web CoralPredict, yang mampu memetakan risiko kerusakan secara spasial dengan akurasi implementasi 94.2% dan korelasi kuat terhadap data lapangan ($r = 0.79$). Hasil pemetaan menunjukkan zona risiko tinggi di Teluk Jakarta, Pantai Utara Jawa, dan Selat Makassar bagian selatan, serta zona risiko rendah di Raja Ampat dan Kepulauan Banda. Meski efektif, model ini masih terbatas oleh ketersediaan data lapangan dan belum mencakup faktor antropogenik.

DAFTAR PUSTAKA

- Suharsono A, Rondonuwu AB, Setyawan D. 2021. Dampak perubahan iklim terhadap degradasi terumbu karang di Indonesia timur. *Jurnal Kelautan Nasional*. 16(2): 78–92.
- LIPI. 2022. Status terumbu karang Indonesia 2021. Jakarta: Lembaga Ilmu Pengetahuan Indonesia. 120 hlm.
- Wicaksono B, Subiyanto B, Pratama C. 2020. Analisis parameter oseanografi terhadap bleaching karang di Raja Ampat. *Jurnal Pesisir dan Lautan*. 14(1): 33–48.
- Pratama D, Kusuma E, Rahman F. 2023. Integrasi data satelit dan machine learning untuk pemantauan terumbu karang. *Prosiding Seminar Nasional Geomatika*. Bogor, 12 Juni 2023. Bogor: Badan Informasi Geospasial. hlm 112–120.
- Burke L, Reytar K, Spalding M, Perry A. 2011. *Reefs at Risk Revisited*. Washington DC: World Resources Institute. 114 hlm.
- Hidayat T, Siregar VP. 2022. Klasifikasi kesehatan terumbu karang menggunakan algoritma pohon keputusan di Kepulauan Seribu. *Jurnal Ilmu Kelautan*. 27(1): 12–25.
- Fadhilah N, Arisandi D. 2023. Optimasi parameter algoritma CART untuk prediksi kerusakan ekosistem pesisir. *Jurnal Teknologi Informasi dan Ilmu Komputer*. 10(2): 211–220.
- Nugroho P, Santoso B, Wijaya C. 2021. Prediksi pemutihan karang berbasis suhu permukaan laut dan kekeruhan di Bali. *Jurnal Teknologi Lingkungan*. 9(3): 45–59.
- Pramono S, Kurniawan A, Saputra D. 2022. Model prediktif degradasi terumbu karang menggunakan machine learning. *Jurnal Kelautan Tropis*. 25(2): 134–147.
- Hastuti R, Wijayanto D, Setiawan A. 2023. Analisis komparasi algoritma decision tree untuk klasifikasi kesehatan terumbu karang. *Jurnal Ilmu Kelautan dan Perikanan*. 15(1): 45–58.

- Kurniawan A, Pratama B, Handayani C. 2021. Penerapan data mining untuk identifikasi faktor dominan kerusakan terumbu karang. *Jurnal Sains dan Teknologi Lingkungan*. 6(3): 89–102.
- NASA Ocean Color. 2024. MODIS Aqua data user guide. <https://oceancolor.gsfc.nasa.gov>. [diakses 15 Januari 2024].
- Li J, Heap AD, Potter A, Daniell JJ. 2011. Application of machine learning methods to spatial interpolation of environmental variables. *Environmental Modelling & Software*. 26(12): 1647–1659.
- García S, Luengo J, Herrera F. 2015. *Data Preprocessing in Data Mining*. Berlin: Springer. 320 hlm.
- Saputra D, Wijaya A. 2022. Evaluasi kinerja algoritma klasifikasi dalam pemantauan terumbu karang. *Jurnal Geomatika Indonesia*. 7(1): 33–45.
- Hasanah MA, Soim S, Handayani AS. 2021. Implementasi CRISP-DM Model menggunakan metode Decision Tree dengan algoritma CART untuk prediksi curah hujan berpotensi banjir. *Journal of Applied Informatics and Computing*. 5(2): 103–108.