

# Klasifikasi Sedimen Dasar Laut Menggunakan Multibeam Echosounder dan Metode Deep Learning

Muhammad Fadhil Ilham<sup>1</sup>, Henry Munandar Manik<sup>2\*</sup>, Sri Pujiyati<sup>2</sup>

<sup>1</sup>Program Studi Magister Teknologi Kelautan, Fakultas Perikanan dan Ilmu Kelautan, Institut Pertanian Bogor

<sup>2</sup>Departemen Ilmu dan Teknologi Kelautan, Fakultas Perikanan dan Ilmu Kelautan, Institut Pertanian Bogor

Jl. Raya Dramaga Bogor Jawa Barat, 16680 Indonesia

Email: henrymanik@apps.ipb.ac.id

## Abstract

### *Seafloor Sediment Classification Using Multibeam Echosounder and Deep Learning Methods*

*Seafloor sediment classification plays an essential role in supporting marine resource management, ecosystem conservation, and coastal development planning. The Multibeam Echosounder (MBES) is an acoustic instrument capable of producing high-resolution bathymetric and backscatter data, providing valuable information for identifying seabed types and physical characteristics. However, conventional classification methods are still constrained by the need for manual feature extraction and sensitivity to data imbalance, which often reduce model reliability. This study aimed to evaluate and compare the performance of several deep learning algorithms for seafloor sediment classification using MBES data collected from the waters of Pari Island, Kepulauan Seribu. The dataset consists of acoustic backscatter, bathymetry, and four derivative bathymetric parameters—slope, rugosity, curvature, and Bathymetric Position Index (BPI)—as input features. A total of 42 sediment samples were collected as ground-truth data, equally divided into 50% for training and 50% for testing. The MBES data were preprocessed using CARIS HIPS and SIPS software, while bathymetric derivatives were generated through ArcGIS 10.8.2. Model performance was evaluated using a confusion matrix and three main metrics: accuracy, F1-score, and kappa coefficient. The results show that deep learning algorithms achieved substantial agreement, with the best-performing model obtaining an accuracy of 83.78%, an F1-score of 83.27%, and a kappa coefficient of 0.67. These research indicate that deep learning-based approaches are effective for seafloor sediment classification and hold strong potential for improving the automation and accuracy of seabed mapping using MBES data.*

**Keywords:** Multibeam Echosounder, Deep Learning, Seafloor Classification, Pari Island

## Abstrak

Klasifikasi sedimen dasar laut memiliki peran penting dalam mendukung pengelolaan sumber daya kelautan, konservasi ekosistem, serta perencanaan pembangunan wilayah pesisir. Multibeam Echosounder (MBES) merupakan instrumen akustik yang mampu menghasilkan data batimetri dan hambur balik (backscatter) beresolusi tinggi, sehingga menyediakan informasi penting untuk mengidentifikasi jenis dan karakteristik fisik dasar laut. Namun, metode klasifikasi konvensional masih menghadapi keterbatasan, seperti kebutuhan ekstraksi fitur secara manual dan sensitivitas terhadap ketidakseimbangan data, sehingga akurasi sering kali tidak konsisten. Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja beberapa algoritma deep learning dalam klasifikasi sedimen dasar laut menggunakan data MBES di perairan Pulau Pari, Kepulauan Seribu. Dataset yang digunakan terdiri atas nilai backscatter akustik, kedalaman batimetri, serta empat parameter turunan batimetri, yaitu slope, rugosity, curvature, dan Bathymetric Position Index (BPI) sebagai fitur masukan. Sebanyak 42 sampel sedimen dasar laut dikumpulkan sebagai data ground truth, kemudian dibagi menjadi 50% untuk pelatihan dan 50% untuk pengujian model. Data MBES diolah menggunakan perangkat lunak CARIS HIPS and SIPS, sedangkan parameter turunan dihitung melalui ArcGIS 10.8.2. Evaluasi model dilakukan menggunakan confusion matrix dengan tiga metrik utama, yaitu accuracy, F1-score, dan koefisien kappa ( $\kappa$ ). Hasil penelitian menunjukkan bahwa algoritma deep learning mampu memberikan kesesuaian yang substansial, dengan model terbaik memperoleh nilai accuracy sebesar 83,78%, F1-score sebesar 83,27%, dan koefisien kappa sebesar 0,67. Penelitian ini menunjukkan bahwa pendekatan deep learning efektif dalam klasifikasi sedimen dasar laut dan berpotensi besar meningkatkan otomatisasi serta ketelitian pemetaan dasar laut berbasis data MBES.

**Kata kunci :** Multibeam Echosounder, Deep Learning, Klasifikasi Sedimen, Pulau Pari

## PENDAHULUAN

Pemetaan sedimen dasar laut memiliki peran penting dalam pengelolaan sumber daya kelautan, konservasi ekosistem, serta perencanaan infrastruktur di wilayah pesisir. Informasi

mengenai jenis dan karakteristik sedimen seperti pasir, lumpur, karang, atau campuran sedimen menjadi dasar bagi pemahaman habitat biota, pengelolaan perikanan, dan rekayasa pantai (Zuraida *et al.*, 2017). Salah satu instrumen utama yang digunakan dalam survei dasar laut adalah *Multibeam Echosounder* (MBES), yang mampu menghasilkan data batimetri dan intensitas hambur balik (*backscatter*) dengan resolusi tinggi (Garone *et al.*, 2023; Wan *et al.*, 2022). Variasi nilai *backscatter* dan topografi dasar laut merepresentasikan sifat fisik sedimen, sehingga dapat digunakan sebagai indikator untuk klasifikasi dasar perairan.

Berbagai pendekatan telah dikembangkan untuk mengklasifikasikan sedimen berdasarkan data MBES, mulai dari analisis statistik, inversi akustik, hingga metode pembelajaran mesin seperti *Support Vector Machine* (SVM) dan *Random Forest* (RF) (Ji *et al.*, 2020; Khomsin & Hadicahyo, 2023). Meskipun efektif, metode tersebut masih menghadapi keterbatasan berupa kebutuhan ekstraksi fitur manual, sensitivitas terhadap ketidakseimbangan kelas, dan ketergantungan pada jumlah data pelatihan yang besar (Cui *et al.*, 2020).

Dalam beberapa tahun terakhir, pendekatan *deep learning* telah banyak digunakan untuk klasifikasi sedimen dasar laut karena kemampuannya mempelajari hubungan nonlinier kompleks tanpa perlu *feature engineering* yang rumit (Ma *et al.*, 2025). Selain itu, parameter turunan batimetri seperti *slope*, *rugosity*, *curvature*, dan *Bathymetric Position Index* (BPI) terbukti meningkatkan kemampuan klasifikasi sedimen karena menggambarkan kondisi geomorfologi dasar laut yang bervariasi (Heap & Harris, 2020; Lecours *et al.*, 2017).

Masalah utama dalam penelitian klasifikasi sedimen dasar laut saat ini adalah masih rendahnya tingkat otomatisasi dalam proses klasifikasi dan keterbatasan data latih yang tersedia. Beberapa algoritma *deep learning* seperti *Convolutional Neural Network* (CNN), *Feedforward Neural Network* (FNN), dan *Tabular Prior-data Fitted Network* (TabPFN) memiliki potensi untuk mengatasi masalah tersebut (Hollmann *et al.*, 2022; Zhao *et al.*, 2023; Cui *et al.*, 2020). Namun, dari ketiga algoritma ini, belum banyak penelitian yang secara langsung membandingkan performanya dalam konteks klasifikasi sedimen dasar laut. Oleh karena itu, perlu dilakukan evaluasi terhadap ketiganya untuk menentukan model *deep learning* yang paling optimal dalam mengklasifikasikan tipe sedimen berdasarkan data MBES.

Penelitian ini bertujuan untuk mengevaluasi serta membandingkan kinerja beberapa algoritma *deep learning* untuk menentukan algoritma terbaik berdasarkan tiga model yaitu TabPFN, CNN, dan FNN dalam klasifikasi sedimen dasar laut menggunakan data MBES di perairan Pulau Pari, Kepulauan Seribu. Evaluasi dilakukan menggunakan data sedimen sebagai *ground truth* untuk menentukan model *deep learning* terbaik berdasarkan *accuracy*, *F1-score*, dan koefisien kappa ( $\kappa$ ).

## MATERI DAN METODE

Penelitian ini dilaksanakan pada bulan Juni hingga Juli 2024 di perairan Pulau Pari, Kepulauan Seribu, DKI Jakarta. Lokasi ini dipilih karena memiliki variasi morfologi dasar laut yang mencakup sedimen pasir, pecahan karang, dan campuran sedimen. Pengumpulan data dilakukan menggunakan kapal nelayan berukuran 12 GT yang dilengkapi sistem survei hidrografi. Alat utama yang digunakan adalah *Multibeam Echosounder* (MBES) Teledyne Reson SeaBat T50-R, yang terhubung dengan *Differential Global Positioning System* (DGPS) dan *Sound Velocity Profiler* (SVP) untuk koreksi posisi serta pengukuran profil kecepatan suara di kolom air. Spesifikasi alat ditampilkan pada Tabel 1.

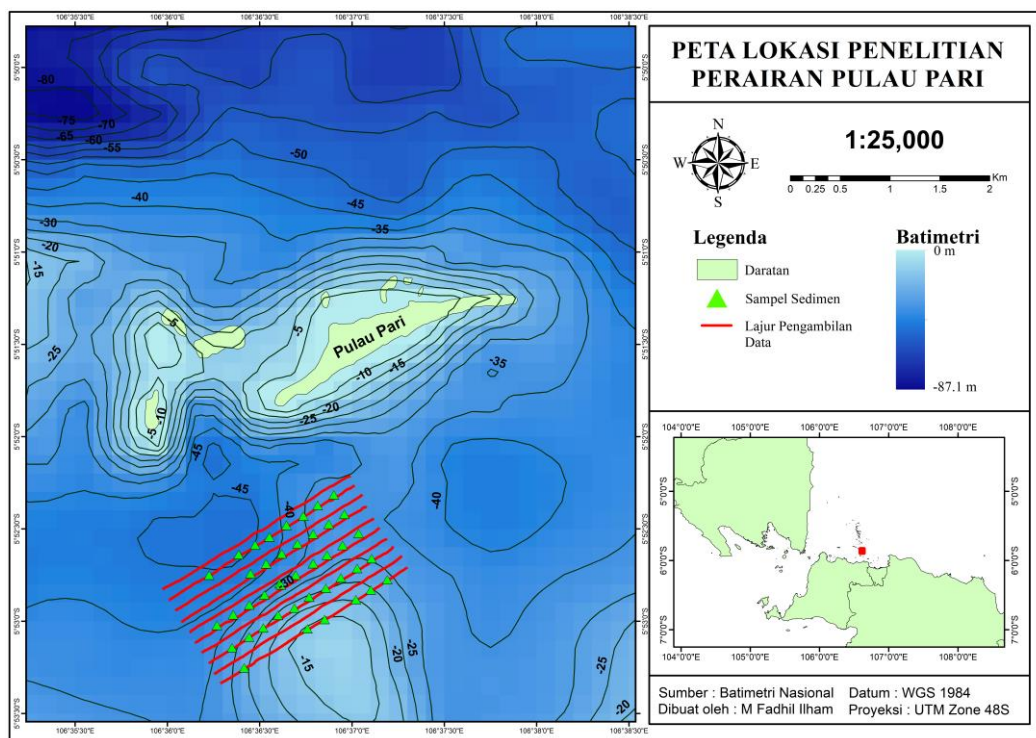
Pemeruman dilakukan dengan mode *Continuous Wave* (CW) menggunakan frekuensi tetap 200 kHz, yang memberikan resolusi tinggi untuk survei di perairan dangkal. Sebelum akuisisi data, dilakukan kalibrasi sistem (*patch test*) antara MBES, DGPS, dan SVP untuk memastikan kesesuaian standar pengoperasian alat, dengan hasil *roll error* sebesar  $-1.18^\circ$ , *pitch error*  $1.13^\circ$ , *yaw error*  $-0.78^\circ$ , serta *latency* sebesar 0.00 s, yang menunjukkan integrasi sensor berjalan optimal. Proses perekaman

dilakukan dengan perangkat lunak PDS2000. Survei dilaksanakan menggunakan lintasan sejajar dan berpotongan yang mengikuti peta lajur yang telah ditentukan, seperti yang dapat dilihat pada Gambar 1.

Pemilihan area survei difokuskan pada bagian selatan Pulau Pari karena wilayah tersebut memiliki variasi morfologi dasar laut yang paling kompleks, meliputi pasir, pecahan karang, dan sedimen campuran yang umum ditemukan pada zona transisi antara terumbu dangkal dan perairan terbuka. Kondisi ini dianggap paling representatif untuk menggambarkan heterogenitas sedimen dan tekstur dasar laut di bagian tengah Kepulauan Seribu (Khomsin & Hadicahyo, 2023; Misiuk *et al.*, 2018; Linklater *et al.*, 2019). Penelitian lokal sebelumnya juga melaporkan bahwa sisi selatan Pulau Pari memiliki variasi geomorfologi dan jenis sedimen yang lebih beragam dibandingkan dengan sisi utara dan timur yang didominasi oleh pasir halus serta endapan organik (Adi *et al.*, 2016).

**Tabel 1.** Spesifikasi Multibeam Echosounder (MBES) Teledyne Reson SeaBat T50-R

Parameter	Spesifikasi
Frequency	190 - 420kHz
Number of beams	10 - 512 beam
Maximum depth range	450 m
Minimum depth range	0,5 m
Ping rate	50 pings/s
Pulse length (CW)	15 - 300 $\mu$ s
Pulse length (FM)	300 $\mu$ s - 10 ms
Depth resolution (max)	6 mm
Depth rating (sonar head)	50 m
Input voltage	100 - 230 VAC 50/60 Hz



**Gambar 1.** Peta lajur survei dan lokasi pengambilan sampel sedimen di perairan Pulau Pari, Kepulauan Seribu.

Dari sisi operasional, area selatan dipilih karena memiliki kedalaman antara 15 – 65 meter dengan kondisi gelombang yang relatif tenang, sehingga aman untuk operasi kapal survei dan sistem MBES. Sementara itu, wilayah pesisir utara dan timur Pulau Pari merupakan area wisata aktif (*snorkeling* dan selam dangkal) dengan kedalaman kurang dari 2 meter, yang berisiko menimbulkan kerusakan pada transduser MBES maupun kapal survei. Kedalaman di area selatan masih berada dalam rentang kerja optimal sistem Teledyne Reson SeaBat T50-R, serta memungkinkan lintasan akuisisi yang stabil dan aman (Garone *et al.*, 2023; Ji *et al.*, 2020).

Pembatasan area penelitian dilakukan untuk menjaga kualitas dan homogenitas data hasil akuisisi agar tetap konsisten secara spasial, serta meminimalkan gangguan akustik akibat variasi kedalaman ekstrem di sekitar tepi terumbu (Diesing *et al.*, 2020; Linklater *et al.*, 2019). Oleh karena itu, area selatan Pulau Pari dinilai paling representatif sekaligus paling aman untuk survei dan analisis sedimen dasar laut menggunakan sistem MBES beresolusi tinggi.

Data hasil akuisisi MBES dalam format \*.s7k diolah menggunakan CARIS HIPS and SIPS untuk koreksi posisi, pembersihan data, serta pembuatan peta batimetri dan mosaik *backscatter*. Hasil pengolahan berupa raster nilai *backscatter* yang telah terkalibrasi kemudian diekstraksi menggunakan ArcGIS 10.8.2 untuk memperoleh data numerik intensitas *backscatter* pada setiap koordinat. Data ini menjadi dasar untuk penggabungan dengan parameter batimetri serta hasil analisis sedimen dari lapangan.

Parameter turunan batimetri yang digunakan dalam penelitian ini meliputi *slope*, *rugosity*, *curvature*, dan *Bathymetric Position Index* (BPI). Keempat parameter tersebut dihitung melalui analisis morfometrik permukaan dasar laut menggunakan ArcGIS 10.8.2, yang menghasilkan representasi spasial geomorfologi dasar perairan Pulau Pari. Parameter turunan ini digunakan sebagai fitur tambahan untuk mendukung klasifikasi sedimen karena memberikan informasi tekstur dan bentuk permukaan dasar laut yang tidak dapat diperoleh hanya dari kedalaman dan *backscatter* (Lecours *et al.*, 2017; Heap & Harris, 2008).

Pengambilan sampel sedimen menggunakan *Van Veen Grab Sampler* dengan metode sampling berupa *Stratified Sampling*, yaitu teknik sampling dengan membagi lokasi sampling menjadi beberapa bagian dengan interval jarak yang sama, tujuannya adalah untuk memastikan bahwa setiap jenis sedimen terwakili secara proporsional. Namun akibat kondisi perairan serta cuaca yang tidak menentu pada saat pengambilan sampel mengakibatkan beberapa titik tidak memungkinkan untuk dilakukan pengambilan sampel, sehingga hanya didapatkan 42 sampel. Sampel dikelompokkan menjadi 2 jenis yaitu *Coral* (karang) yang diberi kode 0 pada model dan *Sand* (pasir) yang diberi kode 1 pada model. Setiap titik sampel dihubungkan dengan koordinat pada peta raster untuk mengekstrak nilai parameter batimetri dan *backscatter* pada lokasi yang sama, sehingga setiap data sedimen memiliki pasangan fitur akustik dan morfometrik yang lengkap. Data hasil ekstraksi kemudian dibagi menjadi 50% untuk pelatihan (*training*) dan 50% untuk pengujian (*testing*) model *deep learning*.

Seluruh data numerik dikonversi ke format tabular dan diolah menggunakan *Microsoft Excel* untuk penggabungan serta penyesuaian nilai agar setiap variabel memiliki skala yang sebanding. Dataset akhir mencakup enam fitur utama yang digunakan sebagai masukan (*input features*) dalam pelatihan model, yaitu hambur balik (*backscatter*), kedalaman (*depth*), *slope*, *rugosity*, *curvature*, dan BPI.

Proses pelatihan model dilakukan menggunakan *Python 3.13.0* dengan pustaka *scikit-learn*, *pandas*, dan *numpy*. Tiga arsitektur *deep learning* diuji, yaitu *Convolutional Neural Network* (CNN), *Feedforward Neural Network* (FNN), dan *Tabular Prior-Data Fitted Networks* (TabPFN). Ketiga model dibandingkan untuk mengevaluasi performa dalam klasifikasi sedimen dasar laut. Evaluasi dilakukan menggunakan *confusion matrix*, yang menggambarkan hubungan antara hasil prediksi dan nilai aktual dari setiap kelas sedimen. Nilai dari *confusion matrix* digunakan untuk menghitung *accuracy*, *F1-score* (Lee *et al.*, 2024), dan *kappa coefficient* ( $\kappa$ ) (Perez *et al.*, 2020), menurut persamaan berikut:

$$Accuracy = \frac{\sum True Prediction}{\sum Sample} \dots\dots\dots (1)$$

$$F1 Score = \sum_{i=1}^N \frac{n_i}{\sum_{j=1}^n n_j} \cdot F1_i \dots\dots\dots (2)$$

$$kappa coefficient = \frac{p_0 - p_e}{1 - p_e} \dots\dots\dots (3)$$

dimana

$$p_0 = \frac{\sum_{i=1}^k n_{ii}}{N} \dots\dots\dots (4)$$

$$p_e = \sum_{i=1}^k \left( \frac{(n_i \times n_{i+1})}{N^2} \right) \dots\dots\dots (5)$$

**HASIL DAN PEMBAHASAN**

Hasil akuisisi menggunakan MBES menghasilkan dua keluaran utama, yaitu peta mosaik batimetri dan peta mosaik *backscatter*. Data batimetri menunjukkan variasi kedalaman dasar perairan Pulau Pari yang berkisar antara 30 hingga 65 meter, dengan morfologi dasar laut yang relatif landai dengan nilai *slope* 3.077<sup>0</sup> dan kecenderungan kedalaman meningkat ke arah barat laut seperti yang ditunjukkan pada Gambar 2 (Goes, *et al.*, 2019). Citra batimetri memperlihatkan variasi topografi halus yang menggambarkan kontur alami dasar laut, termasuk area datar terbuka serta zona dengan kemiringan yang sedikit lebih tinggi di bagian tepi area survei.

Peta mosaik *backscatter* pada Gambar 3 memperlihatkan variasi intensitas *backscatter* akustik antara -26,12 dB hingga -35,75 dB. Nilai *backscatter* tinggi (warna merah-kuning) menunjukkan keberadaan sedimen keras seperti rubble atau kerikil kasar yang memiliki kemampuan reflektif tinggi terhadap gelombang akustik. Sebaliknya, nilai *backscatter* rendah (warna biru-hijau) mengindikasikan sedimen lunak seperti pasir halus, lumpur, atau endapan organik yang lebih banyak menyerap energi gelombang dan memantulkannya lebih sedikit. Secara umum, distribusi sedimen di area penelitian didominasi oleh material dengan tingkat kekasaran menengah hingga kasar.

Berdasarkan hasil pengukuran yang tertera pada tabel 2, nilai *backscatter* sedimen keras seperti karang diperoleh sebesar -30,44 dB, sedangkan sedimen pasir menunjukkan nilai sekitar -33,79 dB. Nilai tersebut masih berada dalam kisaran umum yang dilakukan oleh penelitian terdahulu, di mana sedimen kasar seperti karang dan pecahan batu memiliki nilai antara -25 hingga -30 dB, sementara pasir berkisar antara -30 hingga -33 dB (Diesing *et al.*, 2014; Ji *et al.*, 2020; Hamuna *et al.*, 2018; Elson *et al.*, 2022). Hasil ini mengindikasikan bahwa karakteristik sedimen di perairan Pulau Pari sesuai dengan pola reflektivitas akustik seperti yang diteliti oleh Handoko *et al.* (2025) yang melakukan klasifikasi sedimen akustik menggunakan MBES berfrekuensi tinggi (400 kHz) di lokasi yang sama, yaitu perairan Pulau Pari. Penelitian tersebut menunjukkan kisaran nilai hambur balik antara -27 dB hingga -37,5 dB, dengan perbedaan intensitas yang jelas antara substrat keras seperti karang dan pecahan batu dengan substrat lunak berupa pasir halus dan lumpur.

Nilai *backscatter* yang diperoleh dari hasil akuisisi MBES menunjukkan variasi intensitas yang berkaitan erat dengan jenis dan kekasaran sedimen dasar laut. Kisaran nilai *backscatter* di perairan Pulau Pari berada antara -26,12 dB hingga -35,75 dB. Nilai ini menggambarkan rentang yang umum ditemukan pada perairan tropis dengan variasi sedimen pasir, pecahan karang (*rubble*), dan lumpur. Berdasarkan perbandingan dengan penelitian terdahulu, sedimen bertekstur kasar seperti batuan dan pecahan karang umumnya memiliki nilai *backscatter* tinggi, yaitu sekitar -25 hingga -30 dB, sedangkan pasir berada pada kisaran -30 hingga -33 dB, dan sedimen halus seperti lumpur memiliki nilai lebih rendah dari -34 dB (Diesing *et al.*, 2014; Ji *et al.*, 2020; Linklater *et al.*, 2019; Garone *et al.*, 2023).

Hasil tersebut konsisten dengan penelitian lokal di Indonesia. Hamuna *et al.* (2018) melaporkan bahwa nilai *backscatter* di Teluk Yos Sudarso, Jayapura, bervariasi antara -15,62 dB untuk sedimen karang, -28,40 hingga -27,36 dB untuk pasir, dan -37,81 hingga -35,99 dB untuk lumpur. Demikian

pula, Adi *et al.* (2016) menunjukkan kisaran nilai -16 hingga -13 dB untuk kerikil, -22 hingga -17 dB untuk pasir, -26 hingga -23 dB untuk lumpur, dan -34 hingga -29 dB untuk lempung. Sementara itu, penelitian Elson *et al.* (2022) di Pulau Lancang, Kepulauan Seribu, juga mendokumentasikan nilai *backscatter* -21,08 hingga -24,55 dB untuk pasir sedang, -25,67 hingga -26,67 dB untuk pasir halus, dan -27,42 hingga -28,03 dB untuk pasir halus sekali.

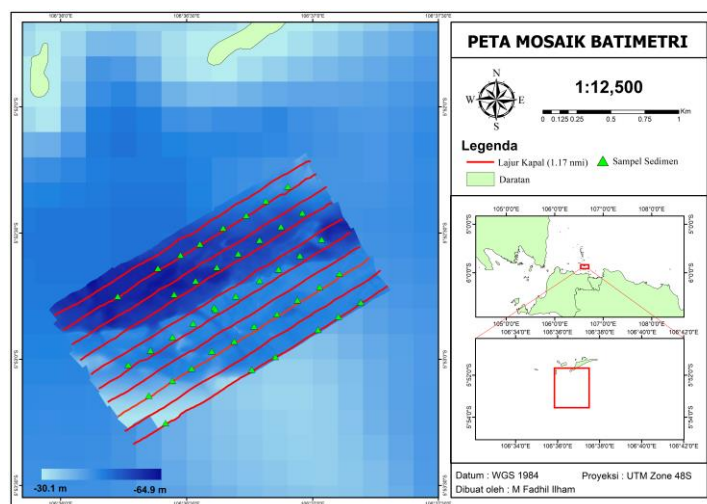
Perbandingan tersebut menunjukkan tren yang seragam bahwa semakin kasar permukaan sedimen, nilai *backscatter* akustik semakin tinggi karena daya pantul terhadap gelombang suara lebih besar, sedangkan sedimen halus cenderung menyerap energi akustik sehingga menghasilkan pantulan lebih rendah (Pujiyati *et al.*, 2010). Dengan demikian, kisaran nilai *backscatter* yang diperoleh pada penelitian ini termasuk dalam rentang yang wajar dan dapat dijadikan dasar untuk klasifikasi sedimen dasar laut di perairan Pulau Pari.

Distribusi spasial nilai *backscatter* menunjukkan pola yang jelas: area dangkal di bagian selatan memiliki nilai lebih tinggi, mengindikasikan sedimen keras seperti *rubble* dan pasir kasar, sedangkan area yang lebih dalam di bagian tengah hingga utara menunjukkan nilai lebih rendah, menandakan dominasi sedimen halus. Pola ini juga sejalan dengan hasil identifikasi sampel sedimen yang diperoleh menggunakan *Van Veen grab* pada lokasi yang sama.

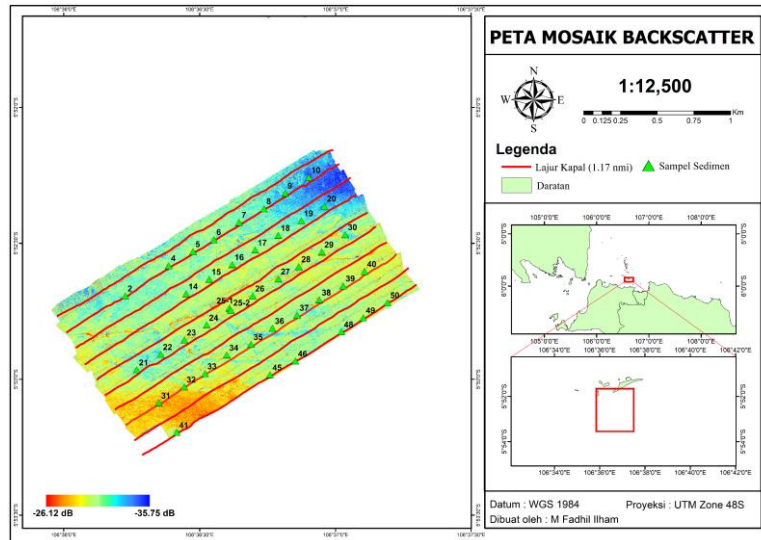
Struktur morfologi batimetri dan intensitas *backscatter* menunjukkan hubungan spasial yang erat. Area dangkal cenderung memiliki nilai *backscatter* tinggi akibat dominasi sedimen keras, sedangkan area lebih dalam memperlihatkan nilai *backscatter* rendah karena didominasi sedimen halus. Pola ini memberikan indikasi awal mengenai variasi jenis sedimen dasar laut di wilayah studi. Secara keseluruhan, hasil pengolahan data MBES memberikan gambaran menyeluruh mengenai kondisi geomorfologi dasar laut dan karakteristik akustik sedimen di perairan Pulau Pari. Peta mosaik batimetri dan *backscatter* yang dihasilkan menjadi dasar penting untuk tahap berikutnya, yaitu ekstraksi parameter turunan batimetri serta klasifikasi sedimen dasar laut menggunakan algoritma *deep learning*.

**Tabel 2.** Tabel Hasil Pengukuran dan Penelitian Terdahulu

Jenis Sedimen	Hasil yang didapatkan	Handoko, <i>et al.</i> (2025)	Hamuna <i>et al.</i> (2018) Perairan Teluk Yos Sudarso
Karang	-30,44 dB	-27 hingga -31 dB	-15,26 dB
Pasir	-33,79 dB	-31 dB hingga -37,5 dB	-27,36 hingga -28,40 dB



**Gambar 2.** Peta mosaik batimetri perairan Pulau Pari, Kepulauan Seribu



**Gambar 3.** Peta mosaik *backscatter* perairan Pulau Pari, Kepulauan Seribu

Dataset hasil ekstraksi dibagi menjadi 50% data pelatihan dan 50% data pengujian. Contoh data pelatihan ditunjukkan pada Tabel 3 yang memuat nilai koordinat dan enam fitur utama yang digunakan dalam proses pelatihan model *deep learning*. Tabel 4 menampilkan cuplikan dataset pengujian yang berisi nilai koordinat, enam fitur utama, hasil klasifikasi model, dan label aktual dari sampel sedimen. Tabel 5 menunjukkan hasil evaluasi kinerja tiga model *deep learning* yang diuji. Berdasarkan nilai *accuracy*, *F1-score*, dan *kappa coefficient*, model TabPFN menunjukkan performa terbaik dibandingkan dua model lainnya.

Model TabPFN menghasilkan akurasi dan konsistensi tertinggi dibandingkan dua model lainnya (Tabel 5). Nilai *accuracy* 0,837, *F1-score* 0,832, dan koefisien kappa 0,672 menunjukkan bahwa TabPFN memiliki tingkat kesesuaian yang substansial antara hasil klasifikasi dan data referensi lapangan (Landis & Koch, 1977). Hal ini mengindikasikan bahwa model mampu mengenali pola distribusi fitur akustik dan morfometrik secara efisien meskipun jumlah data terbatas. Arsitektur TabPFN yang berbasis *transformer* dirancang untuk memproses data tabular secara *end-to-end*, sehingga mampu meniru kemampuan model *ensemble* seperti *Random Forest* namun dengan efisiensi pembelajaran yang lebih baik (Hollmann et al., 2022). Mekanisme *prior-data fitting* memungkinkan model ini beradaptasi dengan cepat pada dataset kecil tanpa kehilangan stabilitas generalisasi.

Sebaliknya, model FNN dan CNN menunjukkan performa yang jauh lebih rendah dengan nilai akurasi sama (0,444), *F1-score* sebesar 0,560 dan 0,571, serta nilai kappa masing-masing 0,072 dan -0,011. Nilai kappa mendekati nol bahkan negatif menandakan adanya *random agreement* atau hasil klasifikasi yang cenderung acak (Rau & Shih, 2021). Rendahnya nilai tersebut disebabkan oleh dua faktor utama yaitu keterbatasan ukuran data pelatihan yang menghambat model dalam membangun representasi spasial yang stabil kemudian ketidakseimbangan jumlah kelas antara sedimen keras (karang, rubble) dan sedimen yang lebih lunak (pasir). Kondisi ini membuat model konvensional seperti CNN dan FNN terlalu terfokus pada kelas mayoritas sehingga akurasi global terlihat rendah, meskipun sensitivitas terhadap satu kelas meningkat. Fenomena ini juga diamati oleh Ghosh et al. (2024), yang menunjukkan bahwa bias kelas mayoritas secara signifikan menurunkan nilai *F1* dan kappa dalam dataset lingkungan dengan proporsi kelas tidak seimbang.

Nilai kappa 0,672 yang diperoleh TabPFN termasuk dalam kategori "substantial agreement" menurut skala Landis dan Koch (1977), menunjukkan bahwa model mampu membedakan kelas dengan tingkat kesepakatan yang baik terhadap label aktual. Hasil ini lebih tinggi dibandingkan dengan beberapa studi terdahulu. Misalnya, Zhao et al. (2023) melaporkan nilai kappa 0,61 dan akurasi 80,9% dalam klasifikasi sedimen berbasis *CNN small-sample learning*. Sementara itu, Ma et al.

(2025) mencatat F1-score 81,5% menggunakan CNN multibeam, dan Cui *et al.* (2020) hanya memperoleh kappa 0,58 dengan pendekatan *fuzzy ranking optimization*. Perbandingan ini menunjukkan bahwa TabPFN memiliki efisiensi pembelajaran lebih baik pada dataset kecil karena mampu menggeneralisasi pola dari data tabular tanpa proses *feature engineering* yang kompleks.

Selain perbedaan arsitektur, karakteristik data Pulau Pari juga berpengaruh terhadap variasi hasil model. Distribusi spasial fitur geomorfik seperti *slope*, *rugosity*, dan *curvature* yang heterogen menyebabkan model FNN dan CNN kesulitan membedakan batas antar kelas sedimen. Dalam hal ini, TabPFN mampu menyesuaikan bobot fitur secara kontekstual dan menghasilkan klasifikasi spasial yang lebih stabil dan konsisten. Hasil penelitian ini juga sejalan dengan Handoko *et al.* (2025) yang melakukan klasifikasi sedimen di lokasi yang sama menggunakan frekuensi tinggi (400 kHz), dengan nilai hambur balik berkisar antara -27 dB hingga -37,5 dB. Mereka menemukan bahwa variasi reflektivitas akustik yang tinggi di wilayah dangkal memerlukan model yang mampu menyesuaikan distribusi fitur nonlinier, seperti yang berhasil dilakukan TabPFN pada penelitian ini.

Kendati demikian, masih terdapat ruang pengembangan, terutama dalam hal pengelolaan ketidakseimbangan kelas. Pendekatan *Synthetic Minority Over-sampling Technique (SMOTE)* dan *pseudo-labelling* sebagaimana disarankan oleh Lee (2013), dan Zhao *et al.* (2023) berpotensi memperbaiki stabilitas model serta meningkatkan kemampuan generalisasi tanpa mengubah proporsi alami data sedimen. Penambahan fitur juga dapat dilakukan dengan menambah beberapa fitur berupa *grain size* pada sampel sedimen, penggunaan pantulan kedua dari *echosounder* sebagai kekasaran lapisan sedimen hingga penggunaan multifrekuensi MBES untuk memberikan hasil model yang lebih stabil serta akurat sebagaimana disarankan oleh Hamuna *et al.* (2014) dan Handoko *et al.* (2026). Dengan demikian, implementasi metode *semi-supervised* pada penelitian berikutnya dapat menghasilkan pemetaan sedimen yang lebih representatif dan akurat.

**Tabel 3.** Cuplikan dataset training (50%) yang digunakan untuk pelatihan model

X	Y	Depth	Backscatter	Slope	Curvature	Rugosity	BPI
106.6165	-5.87078	-41.466	-34.83	13.4723	-92.4736	0.13343	-0.10892
106.6154	-5.87081	-43.475	-32.84	3.34153	-4.72908	0.37860	-0.0102
106.6145	-5.87088	-44.637	-33.62	4.98459	-7.79037	0.57274	-0.02052
106.6144	-5.87089	-44.109	-31.78	4.01276	4.39568	0.57528	0.020863
106.6144	-5.87091	-44.265	-33.46	2.08845	-3.21846	0.31450	-0.00499

**Tabel 4.** Cuplikan dataset testing (50%) dengan hasil klasifikasi model dan label aktual

X	Y	Depth	Back scatter	Slope	Curvature	Rugosity	BPI	kelas	Tipe
106.6088	-5.88097	-45.946	-28.97	0.6823	-0.33836	0.36956	-0.00208	Sand	1
106.6102	-5.87993	-47.046	-29.19	1.26663	2.98653	0.67386	0.007866	Sand	1
106.6102	-5.88005	-47.059	-30.04	0.49132	2.29988	0.44778	0.005703	Coral	0
106.6116	-5.87918	-47.939	-29.48	3.27519	-0.2903	0.49359	-0.00247	Coral	0
106.6132	-5.87814	-44.740	-29.05	0.92905	-2.56424	0.47299	-0.00774	Sand	1

**Tabel 5.** Performa model deep learning dalam klasifikasi sedimen dasar laut

Model	Accuracy	F1-Score	Kappa Coefficient
TabPFN	0.837	0.832	0.672
FNN	0.444	0.560	0.072
CNN	0.444	0.571	-0.011

## KESIMPULAN

Berdasarkan hasil penelitian, MBES mampu menghasilkan data batimetri dan hambur balik (*backscatter*) yang dapat digunakan untuk mengidentifikasi variasi sedimen dasar laut di perairan Pulau Pari, Kepulauan Seribu. Hasil evaluasi model *deep learning* menunjukkan bahwa TabPFN memberikan kinerja terbaik dengan nilai akurasi 83,7%, F1-score 83,2%, dan koefisien kappa 0,67, yang termasuk dalam kategori kesesuaian kuat. Model CNN dan FNN menunjukkan performa lebih rendah dengan akurasi 44,4%, F1-score sekitar 0,56–0,57, serta nilai kappa yang berada dalam kategori lemah. Performa TabPFN yang lebih unggul disebabkan oleh arsitektur berbasis transformer yang efisien dalam mempelajari hubungan *nonlinier* pada data tabular berukuran kecil tanpa memerlukan proses *feature engineering* yang kompleks. Secara keseluruhan, hasil penelitian ini membuktikan bahwa pendekatan *deep learning* berbasis TabPFN memiliki kemampuan tinggi untuk mengklasifikasikan jenis sedimen dasar laut menggunakan data MBES dengan tingkat akurasi yang baik dan konsistensi prediksi yang kuat berdasarkan jenis data yang dimiliki. Pendekatan ini dapat menjadi alternatif potensial dalam pengembangan sistem pemetaan dasar laut otomatis untuk mendukung kegiatan survei kelautan, konservasi, dan pengelolaan sumber daya pesisir.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih atas penggunaan perangkat lunak CARIS HIPS and SIPS sebagai perangkat lunak berlisensi resmi atas nama Sekolah Tinggi Teknik Angkatan Laut (STTAL) dalam pengolahan data MBES meliputi koreksi data, *cleaning* data, hingga pembuatan mosaik *backscatter*. Dukungan melalui lisensi resmi ini sangat berkontribusi besar pada keberhasilan penelitian ini.

## DAFTAR PUSTAKA

- Adi, A.P., Manik, H.M., & Pujiyati, S. (2016). Integrasi data multibeam batimetri dan mosaik backscatter untuk klasifikasi tipe sedimen. *Jurnal Teknologi Perikanan dan Kelautan*, 7(1), 77–84, doi: 10.24319/jtpk.7.77-84 .
- Brown, C.J., Smith, S.J., Lawton, P., & Anderson, J.T. (2011). Benthic habitat mapping: A review of progress towards improved understanding of the spatial ecology of the seafloor using acoustic techniques. *Estuarine, Coastal and Shelf Science*, 92(3), 502–520, doi: 10.1016/j.ecss.2011.02.007.
- Chawla, N.V., Bowyer, K.W., Hall, L.O., & Kegelmeyer, W.P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357, doi: 10.1613/jair.953.
- Cui, X., Yang, F., Wang, X., Ai, B., Luo, Y., & Ma, D. (2020). Deep learning model for seabed sediment classification based on fuzzy ranking feature optimization. *Marine Geology*, 432, 106390, doi: 10.1016/j.margeo.2020.106390.
- Diesing, M., Mitchell, P.J., & Stephens, D. (2014). Mapping seabed sediments: Comparison of manual, geostatistical, object-based image analysis and machine learning approaches. *Continental Shelf Research*, 84, 107–119, doi: 10.1016/j.csr.2014.05.004.
- Elson, L., Manik, H.M., Hestirianoto, T., & Pujiyati, S. (2022). Kuantifikasi hambur balik akustik dasar laut menggunakan scientific single beam echosounder. *Jurnal Ilmu dan Teknologi Kelautan Tropis*, 14(1), 15–29, doi: 10.29244/jitkt.v14i1.37184.
- Garone, R.V., Birkenes Lønmo, T.I., Schimel, A.C.G., Diesing, M., Thorsnes, T., & Løvstakken, L. (2023). Seabed classification of multibeam echosounder data into bedrock/non-bedrock using deep learning. *Frontiers in Earth Science*, 11, 1285368, doi: 10.3389/feart.2023.1285368.
- Ghosh, K., Bellinger, C., Corizzo, R., Branco, P., Krawczyk, B., & Japkowicz, N. (2024). The class imbalance problem in deep learning. *Machine Learning*, 113, 4845–4901, doi: 10.1007/s10994-022-06268-8.
- Goes, E. R., Brown, C. J., & Araujo, T. C. (2019). Geomorphological Classification of the Benthic Structures on a Tropical Continental Shelf. *Frontiers in Marine Science*, 6, 47. doi: 10.3389/fmars.2019.00047

- Hamuna, B., Pujiyati, S., Natih, N.M.N., & Dimara, L. (2018). Analisis hambur balik akustik untuk klasifikasi dan pemetaan substrat dasar perairan di Teluk Yos Sudarso, Kota Jayapura. *Jurnal Ilmu dan Teknologi Kelautan Tropis*, 10(2), 291–300, doi: 10.29244/jitkt.v10i2.24045.
- Handoko, D., Manik, H.M., Hestirianoto, T., Priandana, K., & Hasan, R.C. (2025). Acoustic Sediment Classification Using High-Frequency (400 kHz) Multibeam Data in Pari Water of Seribu Island, Indonesia. *Ilmu Kelautan: Indonesian Journal of Marine Sciences*, 30(1), 135-144. doi: 10.14710/ik.ijms.30.1.135-144
- Heap, A.D., & Harris, P.T. (2008). Geomorphology of the Australian margin and adjacent seafloor. *Australian Journal of Earth Sciences*, 55(4), 555–585, doi: 10.1080/08120090801888669.
- Hollmann, N., Müller, S., Eggensperger, K., & Hutter, F. (2022). TabPFN: A transformer that solves small tabular classification problems in a second. *arXiv preprint arXiv*, 2207.01848.
- Ji, X., Yang, B., & Tang, Q. (2020). Seabed sediment classification using multibeam backscatter data based on selecting optimal random forest model. *Applied Acoustics*, 167, 107387, doi: 10.1016/j.apacoust.2020.107387.
- Khomsin, & Hadicahyo, S. (2023). Deep neural network to classify seabed sediment using MBES multifrequency. *IOP Conference Series: Earth and Environmental Science*, 1276, 012058, doi: 10.1088/1755-1315/1276/1/012058.
- Landis, J.R., & Koch, G.G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174.
- Lecours, V., Dolan, M.F.J., Micallef, A., & Lucieer, V.L. (2016). A review of marine geomorphometry: The quantitative study of the seafloor. *Hydrology and Earth System Sciences*, 20, 3207–3244, doi: 10.5194/hess-20-3207-2016.
- Lee, D.-H. et al. Pseudo-label: the simple and efficient semi-supervised learning method for deep neural networks. In Workshop on Challenges in Representation Learning, ICML, 3, 896.
- Linklater, M., Ingleton, T.C., Kinsela, M.A., Morris, B.D., Allen, K.M., Sutherland, M.D., & Hanslow, D.J. (2019). Techniques for classifying seabed morphology and composition on a subtropical-temperate continental shelf. *Geosciences*, 9(3), 141, doi: 10.3390/geosciences9030141.
- Ma, H., Lai, X., Hu, T., Fu, X., Zhang, X., & Song, S. (2025). Seafloor sediment classification using small-sample multi-beam data based on convolutional neural networks. *Journal of Marine Science and Engineering*, 13(4), 671, doi: 10.3390/jmse13040671.
- Misiuk, B., Lecours, V., & Bell, T. (2018). A multiscale approach to mapping seabed sediments. *PLoS ONE*, 13(2), e0193647, doi: 10.1371/journal.pone.0193647.
- Pérez, J., Díaz, J., Garcia-Martin, J., & Tabuenca, B. (2020). Systematic literature reviews in software engineering - enhancement of the study selection process using Cohen's Kappa statistic. *Journal of Systems and Software*, 168(7), 110657, doi: 10.1016/j.jss.2020.110657.
- Pujiyati, S., Hartati, S., & Priyono, W. (2010). Efek ukuran butiran, kekasaran, dan kekerasan dasar perairan terhadap nilai hambur balik hasil deteksi hidroakustik. *E-Jurnal Ilmu dan Teknologi Kelautan Tropis*, 2(1), 59–67. doi: 10.29244/jitkt.v2i1.7863
- Rau, G., & Shih, Y.S. (2021). Evaluation of Cohen's kappa and other measures of inter-rater agreement for genre analysis and other nominal data. *Journal of English for Academic Purposes*, 53, 101026, doi: 10.1016/j.jeap.2021.101026
- Wan, J., Qin, Z., Cui, X., Yang, F., Yasir, M., Ma, B., & Liu, X. (2022). MBES seabed sediment classification based on a decision fusion method using deep learning model. *Remote Sensing*, 14(15), 3708, doi: 10.3390/rs14153708.
- Zhao, Y., Zhu, K., Zhao, T., Zheng, L., & Deng, X. (2023). Small-sample seabed sediment classification based on deep learning. *Remote Sensing*, 15(8), 2178, doi: 10.3390/rs15082178.
- Zuraida, R., Gerhaneu, N. Y., & Sulistyawan, I. H. (2017). Karakteristik Sedimen Pantai dan Dasar Laut di Teluk Papela, Kabupaten Rote, Provinsi NTT. *Jurnal Geologi Kelautan*, 15(2), 81-94. doi: 10.32693/jgk.15.2.2017.376